



TUGAS AKHIR - TF 141581

**PERANCANGAN SISTEM PENGENDALI *NEURAL NETWORK MODEL PREDICTIVE CONTROL* (NNMPC) PADA KOLOM *DEPROPANIZER***

FEBRIANTO PUTRO WICAKSONO  
NRP. 2413 100 121

Dosen Pembimbing  
Dr. Bambang Lelono W., S.T., M.T.

DEPARTEMEN TEKNIK FISIKA  
Fakultas Teknologi Industri  
Institut Teknologi Sepuluh Nopember  
Surabaya 2017





FINAL PROJECT - TF 141581

***DESIGN OF NEURAL NETWORK MODEL  
PREDICTIVE CONTROL (NNMPC) FOR  
DEPROPANIZER COLUMN***

FEBRIANTO PUTRO WICAKSONO  
NRP. 2413 100 121

Supervisor  
Dr. Bambang Lelono W., S.T., M.T.

DEPARTMENT OF ENGINEERING PHYSICS  
Faculty of Industrial Technology  
Institut Teknologi Sepuluh Nopember  
Surabaya 2017



## PERNYATAAN BEBAS PLAGIASI

Saya yang bertanda tangan di bawah ini:

Nama : Febrianto Putro Wicaksono

NRP : 2413100121

Departemen : Teknik Fisika FTI-ITS

dengan ini menyatakan bahwa tugas akhir saya berjudul **PERANCANGAN SISTEM PENGENDALI *NEURAL NETWORK MODEL PREDICTIVE CONTROL* (NNMPC) PADA KOLOM *DEPROPANIZER*** adalah bebas dari plagiasi. Apabila pernyataan ini terbukti tidak benar, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku.

Demikian surat pernyataan ini saya buat dengan sebenar-benarnya.

Surabaya, 28 Juli 2017

Yang membuat pernyataan,



Febrianto Putro Wicaksono



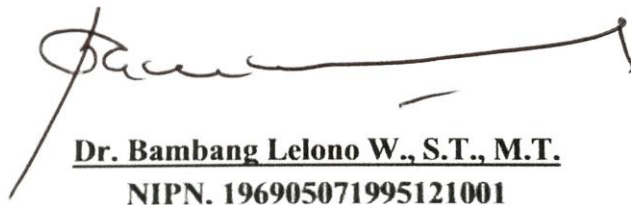
**LEMBAR PENGESAHAN**  
**PERANCANGAN SISTEM PENGENDALI NEURAL**  
**NETWORK MODEL PREDICTIVE CONTROL (NNMPC)**  
**PADA KOLOM DEPROPANIZER**

**TUGAS AKHIR**

Oleh:  
**Febrianto Putro Wicaksono**  
**NRP: 2413100121**

Surabaya, 28 Juli 2017  
**Mengetahui/Menyetujui**

**Pembimbing**

  
**Dr. Bambang Lelono W., S.T., M.T.**  
**NIPN. 196905071995121001**

**Ketua Departemen**  
**Teknik Fisika FTI-ITS**

  
  
**Ageng Muhammad Hana, S.T., M.Si., Ph.D.**  
**NIPN. 197809022003121002**





**LEMBAR PENGESAHAN**  
**PERANCANGAN SISTEM PENGENDALI *NEURAL***  
***NETWORK MODEL PREDICTIVE CONTROL (NNMPC)***  
**PADA KOLOM *DEPROPANIZER***




**TUGAS AKHIR**

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Teknik  
pada  
Bidang Studi Rekayasa Instrumentasi  
Program Studi S-1 Departemen Teknik Fisika  
Fakultas Teknologi Industri  
Institut Teknologi Sepuluh Nopember

Oleh :

**FEBRIANTO PUTRO WICAKSONO**  
NRP. 2413100121

Disetujui oleh Tim Penguji Tugas Akhir :

- |                                      |  |                    |
|--------------------------------------|--|--------------------|
| 1. Dr. Bambang Lelono W., S.T., M.T. |   | ..... (Pembimbing) |
| 2. Hendra Cordova, S.T., M.T.        |   | ..... (Penguji I)  |
| 3. Andi Rahmadiansah, S.T., M.T.     |  | ..... (Penguji II) |

**SURABAYA**  
**JULI, 2017**



**PERANCANGAN SISTEM PENGENDALI *NEURAL NETWORK MODEL PREDICTIVE CONTROL* (NNMPC)  
PADA KOLOM *DEPROPANIZER***

**Nama Mahasiswa** : Febrianto Putro Wicaksono  
**NRP** : 2413 100 121  
**Departemen** : Teknik Fisika FTI-ITS  
**Dosen Pembimbing** : Dr. Bambang Lelono W., S.T., M.T.

**Abstrak**

Kolom *depropanizer* merupakan salah satu kolom distilasi yang digunakan untuk memisah propana dari campuran yang mengandung butana dan komponen lainnya. Untuk memperoleh produk distilasi dengan kemurnian yang tinggi sangat sulit dilakukan jika digunakan pengendalian konvensional karena kolom distilasi memiliki sifat yang sangat *nonlinear*. Oleh karena itu dirancanglah suatu model *neural network* dari kolom *depropanizer* untuk merepresentasikan hubungan *nonlinear* sistem, serta dirancang pula sistem pengendalian *Neural Network Model Predictive Control* (NNMPC) untuk mengendalikan kolom *depropanizer*. Model *neural network* telah mampu memodelkan suatu kolom *depropanizer* dengan baik dimana didapatkan MSE pengujian sebesar  $9.24 \times 10^{-10}$  untuk fraksi mol produk distilat ( $X_d$ ) dan  $4.99 \times 10^{-9}$  untuk fraksi mol produk bawah ( $X_b$ ). Pengendali NNMPC memiliki performansi yang cukup baik ditunjukkan dengan nilai IAE yang lebih kecil dari pengendali PI yaitu sebesar 5.4306 untuk produk distilat ( $X_d$ ) dan 4.6681 untuk produk bawah ( $X_b$ ).

**Kata Kunci:** Kolom *Depropanizer*, *Nonlinear*, *Neural Network*, NNMPC



## **DESIGN OF NEURAL NETWORK MODEL PREDICTIVE CONTROL (NNMPC) FOR DEPROPANIZER COLUMN**

**Name** : Febrianto Putro Wicaksono  
**NRP** : 2413 100 121  
**Department** : Engineering Physics FTI-ITS  
**Supervisor** : Dr. Bambang Lelono W., S.T., M.T.

### **Abstract**

*The depropanizer column is one of the distillation columns used to separate propane from a mixture containing butane and other components. To obtain a high purity distillation product is very difficult to use conventional control because the distillation column has a very nonlinear nature. Therefore a neural network model of depropanizer columns is designed to represent nonlinear relationships, and a Neural Network Model Predictive Control (NNMPC) control system is designed to control the depropanizer column. The neural network model has been able to model a well depropanizer column where MSE test was obtained with  $9.24 \times 10^{-10}$  for the mole fraction of the distillate product ( $X_d$ ) and  $4.99 \times 10^{-9}$  for the mole product fraction ( $X_b$ ). The NNMPC controller has a fairly good performance indicated by IAE value that smaller than the PI controller with 5.4306 for the distillate product ( $X_d$ ) and 4.6681 for the lower product ( $X_b$ ).*

**Keywords:** *Depropanizer Column, Nonlinear, Neural Network, NNMPC*



## KATA PENGANTAR

Puji syukur penulis kepada Allah SWT, karena rahmat dan hikmat-Nya sehingga penulis diberikan kesehatan, kemudahan dan kelancaran dalam menyusun laporan tugas akhir ini. Sehingga penulis mampu menyusun laporan tugas akhir yang berjudul:

### **“PERANCANGAN SISTEM PENGENDALI *NEURAL NETWORK MODEL PREDICTIVE CONTROL* (NNMPC) PADA KOLOM *DEPROPANIZER*”**

Tugas akhir ini merupakan salah satu persyaratan akademik yang harus dipenuhi dalam program studi S-1 Departemen Teknik Fisika FTI-ITS. Penulis menyampaikan terima kasih yang sebesar-besarnya kepada :

1. Segenap keluarga penulis yang telah memberikan dukungan penuh terhadap penyelesaian tugas akhir ini.
2. Bapak Agus Muhammad Hatta, ST, M.Si, Ph.D selaku Ketua Departemen Teknik Fisika ITS.
3. Bapak Dr. Bambang Lelono W, S.T., M.T. selaku dosen pembimbing tugas akhir yang dengan sabar memotivasi dan membimbing penulis untuk menyelesaikan tugas akhir ini.
4. Ibu Dyah Sawitri, S.T., M.T. selaku dosen wali dengan sabar memotivasi dan membimbing penulis selama kuliah di Teknik Fisika.
5. Bapak Totok Ruki Biyanto, Ph.D yang telah ikut membimbing dan membantu saya dalam berkonsultasi selama pengerjaan tugas akhir ini.
6. Janu dan mbak Moudy yang telah membantu dan menyediakan data yang diperlukan dalam penyelesaian tugas akhir ini.
7. Teman-teman Teknik Fisika Angkatan 2013, teman-teman Asisten Laboratorium Rekayasa Instrumentasi dan Kontrol (Larins) yang telah membantu dan memotivasi saya dalam pelaksanaan dan penyusunan laporan tugas akhir ini.

Penulis menyadari bahwa mungkin masih ada kekurangan dalam laporan ini, sehingga kritik dan saran penulis terima. Semoga laporan ini dapat berguna dan bermanfaat bagi penulis dan pihak yang membacanya.

Surabaya, 28 Juli 2017

Penulis



## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>PERNYATAAN BEBAS PLAGIASI .....</b>	<b>v</b>
<b>LEMBAR PENGESAHAN .....</b>	<b>vii</b>
<b>ABSTRAK .....</b>	<b>xi</b>
<b>ABSTRACT .....</b>	<b>xiii</b>
<b>KATA PENGANTAR.....</b>	<b>xv</b>
<b>DAFTAR ISI.....</b>	<b>xvii</b>
<b>DAFTAR GAMBAR.....</b>	<b>xix</b>
<b>DAFTAR TABEL .....</b>	<b>xxi</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan.....	3
1.4 Lingkup Kerja.....	3
1.5 Sistematika Laporan .....	4
<b>BAB II DASAR TEORI.....</b>	<b>5</b>
2.1 Kolom <i>Depropanizer</i> .....	5
2.2 <i>Model Predictive Control</i> .....	10
2.3 <i>Neural Network</i> .....	13
2.4 <i>Neural Network Model Predictive Control</i> .....	19
2.5 Analisis Performansi Pengendalian .....	21
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>25</b>
3.1 Pengumpulan Data dan Pemodelan Proses Kolom <i>Depropanizer</i> .....	27
3.2 Pemodelan Proses Kolom <i>Depropanizer</i> dengan HYSYS.....	29
3.3 Validasi Model Proses Kolom <i>Depropanizer</i> .....	32
3.4 Pengambilan Data Open Loop Kolom <i>Depropanizer</i> .....	32
3.5 Perancangan Model <i>Neural Network</i> .....	36
3.6 Perancangan Pengendali NNMPC .....	38
3.7 Pengujian Performansi Sistem dan Analisa .....	40
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>41</b>
4.1 Pelatihan dan Validasi Model <i>Neural Network</i> .....	41

4.2 Pengujian Model <i>Neural Network</i> .....	46
4.3 Perancangan Pengendali NN MPC .....	48
4.4 Uji Pengendali NN MPC .....	52
<b>BAB V KESIMPULAN DAN SARAN</b> .....	57
5.1 Kesimpulan .....	57
5.2 Saran .....	57
<b>DAFTAR PUSTAKA</b> .....	59
<b>LAMPIRAN A</b> .....	61
<b>LAMPIRAN B</b> .....	67
<b>LAMPIRAN C</b> .....	69
<b>LAMPIRAN D</b> .....	95
<b>LAMPIRAN E</b> .....	103
<b>BIODATA PENULIS</b> .....	105

## DAFTAR GAMBAR

<b>Gambar 2.1</b> <i>Process Flow Diagram (PFD)</i> kolom depropanizer .....	5
<b>Gambar 2.2</b> Bagian-bagian kolom distilasi .....	6
<b>Gambar 2.3</b> Kesetimbangan massa pada kondenser dan <i>reflux</i> <i>drum</i> .....	8
<b>Gambar 2.4</b> Kesetimbangan massa pada <i>reboiler</i> dan <i>base</i> kolom .....	8
<b>Gambar 2.5</b> Kondisi di dalam kolom distilasi .....	10
<b>Gambar 2.6</b> Diagram blok MPC .....	11
<b>Gambar 2.7</b> Konsep Dasar MPC .....	11
<b>Gambar 2.8</b> Bentuk dasar <i>neuron</i> .....	14
<b>Gambar 2.9</b> Struktur <i>multilayer perceptron</i> .....	15
<b>Gambar 2.10</b> Arsitektur NARX .....	17
<b>Gambar 2.11</b> Indentifikasi sistem menggunakan <i>neural</i> <i>network</i> .....	19
<b>Gambar 2.12</b> Struktur dari model <i>neural network</i> .....	20
<b>Gambar 2.13</b> Blok diagram NNMPC .....	21
<b>Gambar 2.14</b> Analisa karakteristik performansi sistem .....	22
<b>Gambar 2.15</b> Respon kesalahan sistem .....	23
<b>Gambar 2.16</b> Respon absolut kesalahan sitem .....	24
 <b>Gambar 3.1</b> Diagram alir penelitian .....	 26
<b>Gambar 3.2</b> Tampilan <i>column environment</i> kolom <i>depropanizer</i> saat kondisi <i>steady state</i> .....	30
<b>Gambar 3.3</b> Tampilan <i>column environment</i> kolom <i>depropanizer</i> saat kondisi <i>dynamic</i> beserta kontrolernya .....	31
<b>Gambar 3.4</b> Grafik <i>open loop</i> laju aliran refluks (L) .....	33
<b>Gambar 3.5</b> Grafik <i>open loop</i> laju panas <i>reboiler</i> (Qr) .....	34
<b>Gambar 3.6</b> Grafik <i>open loop</i> komposisi produk distilat (Xd) .....	35
<b>Gambar 3.7</b> Grafik <i>open loop</i> komposisi produk bawah (Xb) .....	35
<b>Gambar 3.8</b> Struktur model <i>neural network</i> MISO1 .....	37
<b>Gambar 3.9</b> Struktur model <i>neural network</i> MISO2 .....	37

<b>Gambar 4.1</b>	Grafik MSE vs <i>hidden neurons</i> tahap pelatihan dan validasi model MISO1 .....	42
<b>Gambar 4.2</b>	Grafik performa model MISO1 dengan <i>hidden neurons</i> 15.....	43
<b>Gambar 4.3</b>	Grafik respon <i>time-series</i> pelatihan dan validasi model MISO1 dengan <i>hidden neurons</i> 15.....	43
<b>Gambar 4.4</b>	Grafik MSE vs <i>hidden neurons</i> tahap pelatihan dan validasi model MISO2 .....	44
<b>Gambar 4.5</b>	Grafik performa model MISO2 dengan <i>hidden neurons</i> 19.....	45
<b>Gambar 4.6</b>	Grafik respon <i>time-series</i> pelatihan dan validasi model MISO2 dengan <i>hidden neurons</i> 19.....	46
<b>Gambar 4.7</b>	Grafik respon <i>time-series</i> pengujian model MISO1 .....	47
<b>Gambar 4.8</b>	Grafik respon <i>time-series</i> pengujian model MISO2 .....	47
<b>Gambar 4.9</b>	Data input-output dari <i>plant</i> yang dikendalikan oleh NN MPC1 .....	49
<b>Gambar 4.10</b>	Data input-output dari <i>plant</i> yang dikendalikan oleh NN MPC2 .....	51
<b>Gambar 4.11</b>	Plot respon pengendalian NN MPC1 dan PI pada $X_d$ dengan set point 0.95 .....	53
<b>Gambar 4.12</b>	Plot respon pengendalian NN MPC2 dan PI pada $X_b$ dengan set point 0.015 .....	54
<b>Gambar E.1</b>	Model <i>neural network</i> kolom <i>depropanizer</i> pada MATLAB-Simulink .....	103
<b>Gambar E.2</b>	Rancangan pengendali PI pada MATLAB-Simulink .....	103
<b>Gambar E.3</b>	Rancangan pengendali NN MPC pada MATLAB-Simulink .....	104

## DAFTAR TABEL

<b>Tabel 3.1</b> Data parameter utama pada aliran <i>feed</i> kolom <i>depropanizer</i> .....	27
<b>Tabel 3.2</b> Data komposisi komponen pada aliran <i>feed</i> kolom <i>depropanizer</i> .....	28
<b>Tabel 3.3</b> Data spesifikasi <i>depropanizer column</i> .....	28
<b>Tabel 3.4</b> Data spesifikasi <i>depropanizer column reboiler</i> .....	29
<b>Tabel 3.5</b> Data spesifikasi <i>depropanizer condenser</i> .....	29
<b>Tabel 3.6</b> Data spesifikasi <i>depropanizer reflux drum</i> .....	29
<b>Tabel 3.7</b> Data <i>stream</i> kolom <i>depropanizer</i> .....	30
<b>Tabel 3.8</b> Rincian kontrol yang terpasang pada kolom <i>depropanizer</i> .....	32
<b>Tabel 3.9</b> Rincian parameter <i>input</i> APRBS untuk NNMPC1 ....	39
<b>Tabel 3.10</b> Rincian parameter <i>input</i> APRBS untuk NNMPC2 ..	39
<b>Tabel 3.11</b> Rincian nilai parameter pengendali NNMPC1 .....	40
<b>Tabel 3.12</b> Rincian nilai parameter pengendali NNMPC2.....	40
 <b>Tabel 4.1</b> Hasil variasi <i>hidden neurons</i> untuk pengendali NNMPC1 .....	50
<b>Tabel 4.2</b> Hasil variasi <i>hidden neurons</i> untuk pengendali NNMPC2 .....	52
<b>Tabel 4.3</b> Parameter performansi hasil uji Xd.....	53
<b>Tabel 4.4</b> Parameter performansi hasil uji Xb.....	55
 <b>Tabel A.1</b> Validasi data aliran <i>feed</i> .....	61
<b>Tabel A.2</b> Validasi data aliran <i>reflux</i> .....	62
<b>Tabel A.3</b> Validasi data aliran <i>boilup</i> .....	63
<b>Tabel A.4</b> Validasi data aliran <i>to condenser</i> .....	64
<b>Tabel A.5</b> Validasi data aliran <i>to reboiler</i> .....	65
<b>Tabel A.6</b> Validasi data aliran <i>bottom product</i> .....	66
<b>Tabel B.1</b> Hasil pelatihan model <i>neural network</i> MISO1 .....	67
<b>Tabel B.2</b> Hasil pelatihan model <i>neural network</i> MISO2 .....	68
<b>Tabel C.1</b> Tabel perhitungan <i>error</i> pengujian model MISO1 ....	69
<b>Tabel C.2</b> Tabel perhitungan <i>error</i> pengujian model MISO2....	82



# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang

Perkembangan industri yang semakin maju memberikan dampak pada bertambahnya permintaan terhadap suplai energi. Berdasarkan data Kementerian Energi dan Sumber Daya Mineral, pada tahun 2011 komposisi penggunaan energi *final* terbesar ada pada sektor industri dengan nilai sebesar 41% dari total kebutuhan energi *final* di Indonesia [1]. Salah satu unit operasi yang paling banyak digunakan di dunia industri perminyakan dan kimia yang membutuhkan pasokan energi cukup besar adalah kolom distilasi, yaitu sekitar 25-40%. Kolom distilasi mengkonsumsi banyak energi untuk mengubah campuran fluida dengan fase cair ke uap dan mengubah uap kembali menjadi cair pada kondensor [2]. Tidak jarang industri melakukan *over reflux* sehingga energi yang digunakan untuk kolom distilasi biasanya 30-50% lebih besar dari kondisi aktual. Hal ini dilakukan agar produk yang dihasilkan sesuai dengan spesifikasi [3].

Kolom *depropanizer* merupakan salah satu kolom distilasi yang digunakan untuk memisah propana dari campuran yang mengandung butana dan komponen lainnya. Masukan kolom *depropanizer* merupakan *bottom product* dari *deethanizer*. *Depropanizer* memfraksinasi *feed* menjadi *top product* yang kaya propana dan *bottom product* yang terdiri dari butana dan komponen lain yang nantinya akan dijadikan *feed* untuk kolom *debuthanizer* [4]. Untuk memperoleh produk distilasi dengan kemurnian yang tinggi sangat sulit dilakukan jika digunakan pengendalian konvesional karena kolom distilasi memiliki sifat yang sangat *nonlinear* dan karena adanya interaksi yang cukup kuat dan alami antara *loop* yang dikendalikan [5]. Komposisi produk *distillate* dapat dikendalikan dengan mengatur aliran *reflux*, begitu juga komposisi *bottom product* dapat dikendalikan dengan mengatur masukkan panas pada *reboiler*. Perubahan laju alir pada *reflux* dapat mempengaruhi kualitas *bottom product* begitu juga sebaliknya [6].

Penerapan sistem pengendalian konvensional yang bersifat *linear* disadari kurang mampu memberikan performansi yang baik akibat dari pembatasan yang harus dilakukan saat perencanaan awal. Pembatasan tersebut ialah linearisasi dan pembatasan daerah operasi. Padahal kolom distilasi memiliki karakteristik yang *nonlinear* dan kompleks. Hal ini akan menghalangi kesuksesan penerapan sistem pengendalian *linear*. Selain itu, pembatasan daerah operasi proses yang sempit dapat menimbulkan masalah jika diinginkan perubahan daerah operasi yang lebih luas. Performansi sistem pengendalian *linear* akan mengalami penurunan atau bahkan ketidakstabilan jika daerah operasi tidak sesuai dengan daerah operasi perancangan awalnya. Berdasarkan hal-hal tersebut maka perlu dirancang suatu sistem pengendalian *nonlinear* untuk mengatasi karakteristik proses yang *nonlinear* [7].

*Model Predictive Control* atau biasa disebut sebagai kontrol prediktif merupakan salah satu jenis *advanced control* yang memberikan dampak signifikan terhadap perkembangan sistem kontrol di industri. Kontrol prediktif menggunakan *internal model* sistem yang sebenarnya untuk memprediksi perilaku masa depan sistem mulai saat ini sampai interval waktu tertentu [8]. Dengan demikian mutlak diperlukan adanya suatu model yang merepresentasikan proses yang ditinjau. Namun pengembangan model *nonlinear* dan multivariabel dengan persamaan matematis masih merupakan kendala tersendiri berkaitan dengan jumlah persamaan yang dibutuhkan serta waktu penyelesaian yang lama. Hal ini dapat diatasi dengan memanfaatkan kelebihan yang dimiliki *neural network* dalam memetakan hubungan *nonlinear* antara *input-output*. Dimana informasi mendalam mengenai proses yang ditinjau tidak lagi diperlukan [9]. Oleh karena itu pada tugas akhir ini dirancanglah suatu model *neural network* dari kolom *depropanizer* untuk merepresentasikan hubungan *nonlinear* sistem, serta perancangan sistem pengendalian *Neural Network Model Predictive Control* (NNMPC) untuk mengendalikan komposisi komponen pada kolom *Depropanizer*, sehingga diharapkan nantinya didapatkan performansi sistem yang lebih baik.



## 1.2 Rumusan Masalah

Berdasarkan latar belakang diatas maka permasalahan yang diambil dalam tugas akhir ini yaitu:

- a. Bagaimana cara memodelkan kolom *depropanizer* menggunakan *neural network*?
- b. Bagaimana performansi dari sistem pengendali NNMPCC dalam mengendalikan komposisi komponen pada kolom *depropanizer*?

## 1.3 Tujuan

Adapun tujuan dilakukannya tugas akhir ini adalah sebagai berikut:

- a. Untuk merancang model *neural network* kolom *depropanizer*.
- b. Menganalisa perfomansi sistem pengendali NNMPCC dalam mengendalikan komposisi komponen pada kolom *depropanizer* agar diperoleh unjuk kerja kolom distilasi yang baik dengan hasil *output* sesuai harga yang diinginkan.

## 1.4 Lingkup Kerja

Ruang lingkup kerja yang dikaji dalam tugas akhir ini meliputi:

- a. Simulasi sistem kolom *depropanizer* menggunakan HYSYS V8.8.
- b. Variabel dikendalikan adalah komposisi produk distilat ( $X_D$ ) dan produk bawah ( $X_B$ ) dengan memanipulasi laju aliran *reflux* ( $L$ ) dan laju aliran *steam reboiler* ( $Q_R$ ).
- c. Struktur *neural network* menggunakan NARX (Non-Linear AutoRegresive with eXogenous Input) dengan algoritma pembelajaran Levenberg Marquardt.
- d. Pemodelan *neural network* kolom *depropanizer* serta simulasi pengendali NNMPCC menggunakan MATLAB 2013b.

## **1.5 Sistematika Laporan**

Secara sistematis, laporan tugas akhir ini tersusun dalam lima bab dengan penjelasan sebagai berikut:

### **BAB I Pendahuluan**

Bab ini berisi latar belakang, rumusan masalah, tujuan, lingkup kerja, dan sistematika laporan dari tugas akhir.

### **BAB II Dasar Teori**

Bab ini berisi tentang teori-teori yang mendasari penelitian. Teori-teori tersebut diantaranya meliputi dasar teori tentang kolom *depropanizer*, *model predictive control* (MPC), *neural network*, *neural network model predictive control* (NNMPC), serta penjelasan mengenai analisis performansi pengendalian.

### **BAB III Metodologi Penelitian**

Pada bab ini dijelaskan tentang langkah-langkah dan tahapan penelitian dimulai dari pengumpulan data komponen dan konfigurasi kolom *depropanizer*, pemodelan proses kolom *depropanizer* dengan HYSYS, validasi model proses kolom *depropanizer*, pengambilan data *open loop* kolom *depropanizer*, perancangan model *neural network* kolom *depropanizer*, perancangan pengendali NNMPC, hingga pengujian performa sistem dan analisa.

### **BAB IV Analisis Data dan Pembahasan**

Bab ini menunjukkan data beserta analisis dan pembahasan yang telah diperoleh selama pengerjaan penelitian.


### **BAB V Kesimpulan dan Saran**

Bab ini memaparkan kesimpulan dan saran terkait dengan tugas akhir yang telah dilaksanakan.

## BAB II DASAR TEORI

### 2.1 Kolom Depropanizer


Kolom *depropanizer* merupakan salah satu kolom distilasi yang digunakan untuk memisah propana dari campuran yang mengandung butana dan komponen lainnya. Masukan kolom *depropanizer* merupakan *bottom product* dari kolom *deethanizer*. *Depropanizer* memfraksinasi *feed* menjadi produk yang kaya propana dan *bottom product* yang terdiri dari butana dan minyak gas alam. Keluaran atas dari kolom *depropanizer* yang kaya akan propana akan dikondensasikan dalam kondensor oleh air pendingin, kemudian kondensat dikumpulkan di *reflux drum*. Sebagian kondensat dikirim kembali ke kolom dengan menggunakan pompa sedangkan sebagian lainnya yang tersisa ditarik sebagai produk propana cair. *Bottom product* dari kolom *depropanizer* kemudian dikirim ke *debuthanizer*.



**Gambar 2.1** Process Flow Diagram (PFD) kolom *depropanizer*

Kolom *depropanizer* adalah kolom distilasi yang berfungsi untuk memisahkan propana dari fraksi berat lainnya berdasarkan volatilitas zat. Tidak hanya itu, pemisahan komponen juga tergantung dari konsentrasi komponen tersebut. Dengan alasan inilah proses distilasi dikatakan tergantung pada karakteristik tekanan uap campuran [10]. Fluida cair yang akan diproses dikenal sebagai *feed* dan dimasukkan ke nampan (*tray*) yang dinamakan *feed tray*. *Feed tray* membagi kolom menjadi bagian atas (*rectifying*) dan bagian bawah (*stripping*) [11].

Berikut merupakan gambaran sederhana dari kolom distilasi secara umum.



**Gambar 2.2** Bagian-bagian kolom distilasi

Kesetimbangan massa dari kolom distilasi adalah sebagai berikut:

$$F = D + B \quad (2.1)$$

dimana:

$F$  = laju aliran *feed*

$D$  = laju aliran distilat

$B$  = laju aliran *bottom product*

Dengan kesetimbangan massa komponen kolom distilasi sebagai berikut:

$$FX_F = DX_D + BX_B \quad (2.2)$$

$X_F$  = fraksi *feed*

$X_D$  = fraksi distilat

$X_B$  = fraksi *bottom product*

Sedangkan kesetimbangan massa *total* pada kondensor dan *reflux* dapat dirumuskan sebagai berikut:

$$\frac{dM_D}{dt} = V_T - L - D \quad (2.3)$$

dimana:

$V_T$  = laju aliran *vapour* keluaran *top stage* kolom

$L$  = laju aliran *reflux*

Dan kesetimbangan massa komponen pada kondenser dirumuskan sebagai berikut:

$$\frac{d(M_D X_D)}{dt} = V_T X_{V_T} - (L + D) X_D \quad (2.4)$$

dimana  $X_{V_T}$  merupakan fraksi dari *vapour* keluaran kolom distilasi.

Sehingga kesetimbangan massa energi pada kondenser dapat ditulis dengan rumus sebagai berikut:


$$\frac{d(M_D h_D)}{dt} = V_T h_{V_T} - L h_L - D h_D + Q_C \quad (2.5)$$

dimana:


$h_{V_T}$  = entalpi pada *vapour* keluaran *top stage* kolom

$h_D$  = entalpi pada distilat

$h_L$  = entalpi pada *reflux*  
 $Q_C$  = *heat flow* kondenser



**Gambar 2.3** Kestimbangan massa pada kondenser dan *reflux drum*



**Gambar 2.4** Kestimbangan massa pada *reboiler* dan *base* kolom

Untuk kesetimbangan massa total pada *reboiler* dan *base* kolom dapat dituliskan dengan rumus sebagai berikut:

$$\frac{dM_B}{dt} = L_1 - V_{RB} - B \quad (2.6)$$

dimana:

$L_1$  = laju aliran keluaran *bottom stage* kolom

$V_{RB}$  = laju aliran *steam reboiler*

dengan kesetimbangan massa komponen sebagai berikut:

$$\frac{d(M_B X_B)}{dt} = L_1 X_1 - V_{RB} X_{V_{RB}} - B X_B \quad (2.7)$$

dimana:

$X_1$  = fraksi keluaran *bottom stage* kolom

$X_{VRB}$  = fraksi *steam reboiler*

dan kesetimbangan massa energi pada *reboiler* dan *base* kolom dapat dirumuskan sebagai berikut:

$$\frac{d(M_B h_B)}{dt} = L_1 h_1 - V_{RB} h_{V_{RB}} - B h_B + Q_B \quad (2.8)$$

dimana:


$h_1$  = entalpi keluaran *bottom stage* kolom

$h_{RB}$  = entalpi *steam reboiler*

$h_B$  = entalpi *bottom product*

$Q_B$  = *heat flow* pada *reboiler*

Di dalam kolom distilasi terdapat beberapa nampan (*trays*). Setiap *tray* memiliki 2 saluran di masing-masing sisinya yang disebut dengan *downcomers*. Fluida cair jatuh melalui *downcomers* dari satu *tray* ke *tray* lainnya [12]. *Tray* dirancang untuk memaksimalkan kontak antara fase gas dan cair dengan mempertimbangkan distribusi cairan dan distribusi uap. Hal ini dikarenakan bila kontak antara fase gas dan cair lebih maksimal maka akan lebih baik pemisahan yang terjadi pada setiap *tray*. Kondisi dalam kolom distilasi dapat dilihat pada gambar di bawah ini.



**Gambar 2.5** Kondisi di dalam kolom distilasi


*Tray* pada kolom distilasi memiliki banyak lubang yang berfungsi untuk lajur aliran uap. Uap mengalir ke atas kolom dan dipaksa untuk melewati cairan melalui bukaan pada setiap *tray*. Saat uap panas melewati cairan dari *tray* satu ke *tray* lainnya, uap tersebut mentransfer panas ke cairan sehingga sebagian uap terkondensasi dan menambah cairan pada *tray*. Sisa uap lainnya kemudian keluar melalui atas kolom dan didinginkan oleh kondenser. Sebagian cairan ini dimasukkan kembali ke atas kolom dan disebut *reflux*. Sedangkan sebagian lainnya dikeluarkan dari sistem dan disebut sebagai *distillate* dan *top product*. Panas dipasok ke *reboiler* untuk menghasilkan uap. Uap pada *reboiler* tersebut kembali dimasukkan ke dalam unit melalui bagian bawah kolom. Cairan keluaran dari *reboiler* dikenal sebagai *bottom product* [12].

## 2.2 Model Predictive Control


*Model Predictive Control* (MPC) atau sistem kendali prediktif termasuk dalam konsep perancangan pengendali berbasis model proses, dimana model proses digunakan secara eksplisit untuk merancang pengendali dengan cara meminimumkan suatu fungsi kriteria. MPC dapat memprediksi perilaku proses dimasa depan dengan menggunakan model dinamis dan pengukuran yang



tersedia. *Output* pengendalian akan dihitung sehingga dapat meminimalkan *error*.



**Gambar 2.6** Diagram blok MPC [13]



**Gambar 2.7** Konsep Dasar MPC [14]

Gambar 2.6 dan 2.7 diatas menunjukkan diagram blok dari sistem MPC dan konsep dasar MPC. Fungsi objektif dari perhitungan kontrol MPC adalah untuk menentukan urutan dari *control moves* sehingga respon dari *output* prediksi bergerak menuju *set point* pada kondisi yang optimal.

Metodologi MPC dalam menentukan prediksi *output* adalah sebagai berikut :

- a. *Output* di masa depan diprediksi dengan menggunakan model proses berdasarkan pada nilai *input* dan *output* yang lampau. *Output* proses yang akan datang diprediksi sejauh *prediction horizon* yang diprediksi pada setiap waktu pencuplikan (*sampling time*).
- b. Serangkaian sinyal kontrol masa depan dihitung sejauh *control horizon* dengan mengoptimasi suatu fungsi kriteria yang ditetapkan sebelumnya untuk menghasilkan nilai yang optimal. Fungsi tersebut umumnya berupa suatu fungsi kuadratik dari kesalahan antara prediksi *output* dengan *output* acuan.
- c. Prediksi *output* yang sudah dihitung dikirim kembali ke proses. Hal ini terjadi berulang-ulang dengan nilai prediksi *output* yang baru dan semua prosedur perhitungan yang diperlukan diperbaiki.

MPC memiliki beberapa parameter yang dapat membantu menghasilkan respon yang baik dan stabil dalam simulasi. Parameter tersebut meliputi matriks bobot R dan Q, *control horizon* ( $N_c$ ), *prediction horizon* ( $N_p$ ) dan *sampling time* ( $T_s$ ). *Prediction horizon* merupakan jumlah langkah yang ditentukan untuk memprediksi *output*. Semakin besar nilai  $N_p$  maka respon yang dihasilkan dapat lebih baik, namun ada batasan tersendiri dalam menentukan *prediction horizon*. *Control horizon* ( $N_c$ ) ditentukan untuk seberapa banyak tindakan kontrol masa depan yang dihitung disetiap langkah optimasi. Secara umum, jika *control horizon* yang digunakan bernilai kecil maka respon yang dihasilkan akan lebih baik.

Berikut adalah beberapa kelebihan yang dimiliki oleh MPC dibandingkan dengan pengendali konvensional.

- a. Merupakan metode yang umum untuk pengendalian proses dengan sistem *multi input multi output* (MIMO) yang didalamnya terdapat interaksi diantara lup-lup yang dikendalikan.

- b. Dapat dengan mudah mengakomodasi perilaku dinamis yang sangat sulit atau tidak biasa seperti penundaan waktu yang besar dan respon *invers*.
- c. *Constraints* dapat diperhitungkan didalam perancangan pengendali.


Namun disamping memiliki kelebihan yang tidak bisa dilakukan oleh pengendali konvensional, pengendali MPC juga memiliki kekurangan, diantaranya adalah :

- a. Pengendali MPC ini berbeda sekali dengan pengendali konvensional yang sudah sangat lama digunakan di industri, sehingga pengendali ini kurang dikenali oleh operator.
- b. Pengembangan model dinamik dari data *plant* membutuhkan waktu yang lama apalagi jika prosesnya sangat kompleks.
- c. Karena model empirik adalah yang biasa digunakan, maka hanya valid untuk *range* dan kondisi tertentu sesuai dengan waktu pengujiannya.

## 2.3 Neural Network

Secara umum *Neural Network* (NN) adalah jaringan dari sekelompok unit pemroses kecil yang dimodelkan berdasarkan jaringan syaraf manusia. NN ini merupakan sistem adaptif yang dapat merubah strukturnya untuk memecahkan masalah berdasarkan informasi *eksternal* maupun *internal* yang mengalir melalui jaringan tersebut. Secara sederhana NN adalah sebuah alat pemodelan data statistik *non-linear*. NN dapat digunakan untuk memodelkan hubungan yang kompleks antara *input* dan *output* untuk menemukan pola-pola pada data. Secara mendasar, sistem pembelajaran merupakan proses penambahan pengetahuan pada NN yang sifatnya kontinuitas sehingga pada saat digunakan pengetahuan tersebut akan dieksploitasikan secara maksimal dalam mengenali suatu objek. Neuron adalah bagian dasar dari pemrosesan suatu Neural Network.

Dibawah ini merupakan bentuk dasar dari suatu neuron.



**Gambar 2.8** Bentuk dasar neuron

Keterangan dari Gambar 2.8 di atas adalah sebagai berikut.

- Input*, merupakan masukan yang digunakan baik saat pembelajaran maupun dalam mengenali suatu objek.
- Weight*, beban yang selalu berubah setiap kali diberikan input sebagai proses pembelajaran.
- Processing Unit*, merupakan tempat berlangsungnya proses pengenalan suatu objek berdasarkan pembebanan yang diberikan.
- Output*, keluaran dari hasil pengenalan suatu objek.

### 2.3.1 Pemodelan dengan *Neural Network*


Pemodelan dengan neural network/jaringan saraf tiruan (JST) adalah pemodelan *black box* dimana *input* dipasangkan dengan *output* yang sesuai. Didalam jaringan saraf tiruan terdiri dari sambungan (*connections*) dan elemen pemrosesan (*neuron*).

Untuk pemodelan sistem, ada beberapa keuntungan menggunakan jaringan saraf tiruan yaitu: [15]

- Sistem *Nonlinear*. Jaringan saraf tiruan mempunyai kemampuan untuk memetakan hubungan yang tidak linier, sehingga sangat menjanjikan untuk mengatasi permasalahan kontrol *nonlinear*.
- Pembelajaran dan beradaptasi. Jaringan saraf tiruan yang telah ditraining menggunakan satu set data akan mampu mengeluarkan *output* sama atau mendekati *output* pasangan *input* yang diberikan, bahkan mampu mengeluarkan *output* dengan *input* yang belum pernah dilatihkan. Jaringan saraf tiruan mampu juga dilatih *on-line*.

- c. Sistem Multivariabel. Jaringan saraf tiruan juga dapat di aplikasikan untuk multi-variabel proses. Struktur jaringan saraf tiruan yang umum adalah multilayer perceptron (MLP). Gambar menggambarkan struktur MLP, yang terdiri dari *input*, *hidden* dan *output layer*.

Cybenko menunjukkan bahwa pemodelan untuk semua fungsi kontinyu dapat dicapai akurasi model yang diinginkan dengan menggunakan JST dengan struktur sebuah *hyperbolic tangent* pada *hidden neuron* dan sebuah linear pada *output neuron*. Dalam rangka menentukan bobot misalnya *output*  $y_i$  dihubungkan dengan *input*  $\varphi_i$ , maka memerlukan suatu usaha yang disebut pelatihan/pembelajaran (*training/learning*). Dalam *training* bobot disesuaikan agar memperoleh *output* jaringan yang sesuai dengan *output* proses atau target. Algoritma pembelajaran ini akan terus menyesuaikan bobot sampai target yang diinginkan tercapai [16].



**Gambar 2.9** Struktur *multilayer perceptron*

Secara matematis multilayer perceptron dapat ditulis:

$$y_i = F_i \left[ \sum_{j=1}^{n_h} W_{i,j} f_j \left( \sum_{l=1}^{n_\varphi} w_{j,l} \varphi_l + w_{j,0} \right) + W_{i,0} \right] \quad (2.9)$$


### 2.3.2 Neural Network Non-Linier Auto-regresive with eXogenous Input (NN NARX)

Bergantung pada konfigurasi aliran sinyalnya, NN dapat diklasifikasikan ke dalam *feedforward* NN dan *recurrent* NN. Dalam *feedforward* NN, *output* dihitung langsung dari *input* melalui koneksi *feedforward*. *Feedforward* NN sebagian besar adalah jaringan statis. Sedangkan *recurrent* NN sifatnya lebih dinamis dan memiliki setidaknya satu tanggapan lingkaran. Oleh karena itu output jaringan bukanlah hasil dari proses input eksternal saja.

NARX merupakan bagian dari *recurrent* NN. Sistemnya memiliki *feedback* yang terkoneksi kembali melampirkan beberapa lapisan jaringan. Arsitektur yang mencakup *taped delay lines* (TDL) yang menahan pola dari input yang sudah masuk. Hal ini membuat sistem tersebut lebih cocok untuk prediksi ke depan (prediksi *time-series*) dari jaringan *feedforward*. Oleh karena itu lebih tepat untuk menggunakannya untuk pemodelan dinamis. *Input* biasanya berupa vektor masukan yang terjadi dalam urutan waktu tertentu. Sebuah model NARX secara umum didefinisikan oleh persamaan:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y); u(t-1), u(t-2), u(t-n_u)) \quad (2.10)$$

$y(t)$  adalah nilai saat ini dari sinyal *output* yang dinyatakan dalam fungsi dari nilai sebelumnya dari sinyal *output*  $y(t-1)$ ,  $y(t-2)$ , ...,  $y(t-n_y)$  dan nilai-nilai sebelumnya dari sinyal independen *input*  $u(t-1)$ ,  $u(t-2)$ ,  $u(t-n_u)$ . Adapun skema dari penggunaan data dengan arsitektur NARX dapat dilihat pada gambar 2.10.



**Gambar 2.10** Arsitektur NARX

### 2.3.3 Algoritma Levenberg-Marquadt

Algoritma pembelajaran yang digunakan dalam penelitian ini adalah algoritma *Levenberg Marquardt*. Meskipun algoritma ini lebih kompleks dibandingkan algoritma *backpropagation*, tetapi algoritma ini dapat memberikan hasil yang lebih baik, terutama pada proses dengan orde banyak (lebih dari satu). Penurunan algoritma ini dapat dijelaskan sebagai berikut: [17]

- a. Inisialisasi bobot dan bias dengan bilangan acak, *epoch* maksimum, dan minimal *goal* (*performance* yang dihitung dengan MSE).
- b. Menentukan parameter yang dibutuhkan, antara lain:
  - Parameter *Levenberg Marquardt* yang nilainya harus lebih besar dari nol
  - Parameter faktor Beta ( $\beta$ ) yang digunakan sebagai parameter yang dikalikan atau dibagi dengan parameter *Levenberg Marquardt*. Penjelasan ada pada *step* berikutnya.
- c. Menghitung maju (*feedforward*) pada *hidden* dan *ouput layer* seperti langkah-langkah pada algoritma *error backpropagation*.
- d. Menghitung nilai MSE
- e. Menghitung *error* dan *total error* jaringan
  - Rumus untuk *error*:

$$er = tr - yr \quad (2.11)$$

r merupakan inputan ke-r

- Rumus untuk menghitung *total error*:

$$e = [e_1 e_2 e_3 \dots e_N]^T \quad (2.12)$$

e merupakan vektor kesalahan berukuran  $N \times 1$  yang terdiri dari  $e_r$   $r = 1, 2, 3 \dots N$

- f. Menghitung matriks *jacobian*  $J(x)$  x merupakan matriks yang berisi bobot dan bias dari keseluruhan jaringan.

$X = [v_{11}, v_{12}, \dots, v_{ij}; v_{01}, v_{02}, \dots, v_{0j}; w_{11}, w_{12}, \dots, w_{jk}; w_{01}, w_{02}, \dots, w_{0k}]$

Matriks *jacobian* berisi turunan pertama error jaringan terhadap bobot dan bias jaringan. Rumus untuk mencari *jacobian* matriks antara lain.

$$J = \left[ \frac{\partial e_r}{\partial w} \right] \quad (2.13)$$

- g. Setelah didapatkan nilai  $J(x)$  maka dapat dihitung perubahan koreksi bobot dan biasnya dengan rumus berikut:

$$\Delta x = [J(x)^T J(x) + \mu I]^{-1} * Gradient \quad (2.14)$$

$$Gradient = J(x)^T * e \quad (2.15)$$

- h. Setelah didapatkan nilai delta  $\Delta x$  tahap selanjutnya adalah pengkoreksian bobot dengan rumus yang sama seperti pada algoritma *error backpropagation*.
- i. Menghitung maju (*feedforward*) dengan bobot dan bias yang baru.
- j. Menghitung MSE jaringan dengan bobot dan bias yang baru. Kemudian tes kondisi berhenti.
- k. Jika epoch atau iterasi masih berlanjut maka akan terdapat 2 kemungkinan kondisi berikut:
- Jika MSE naik  $\beta \mu x$
  - Jika MSE turun  $\beta \mu$




Kemudian melakukan kembali langkah 5 sampai langkah 8.

## 2.4 Neural Network Model Predictive Control

*Neural Network Model Predictive Control* (NNMPC) merupakan suatu strategi kontrol yang menggunakan model *neural network* dari suatu *nonlinear plant* untuk memprediksi performansi *plant* kedepannya. Kontroller kemudian dapat menghitung *input* kontrol yang akan meng-optimalkan kinerja *plant* selama masa horizon waktu yang ditentukan. Untuk dapat merancang pengendali NNMPC umumnya terdapat dua tahapan, yaitu identifikasi sistem dan implementasi dari model *neural network* pada kontrol prediktif [18].


### 2.4.1 Identifikasi Sistem

Tahap pertama dari perancangan NNMPC adalah identifikasi sistem. Pada tahap ini dilakukan pelatihan sebuah *neural network* untuk merepresentasikan dinamika *plant* kedepannya. *Error* atau selisih prediksi antara *output* dari *plant* dan *output* dari *neural network* akan digunakan sebagai sinyal untuk pelatihan model *neural network*. Proses akan di representasikan oleh gambar berikut ini:



**Gambar 2.11** Identifikasi sistem menggunakan *neural network*

Model *neural network* dari *plant* akan menggunakan input sebelumnya dan *output plant* sebelumnya untuk memprediksi nilai dari *output plant* kedepannya. Struktur model *neural network* dari *plant* dapat digambarkan sebagai berikut:



**Gambar 2.12** Struktur dari model *neural network*

*Neural network* ini juga dapat dilatih secara *offline* dalam modus batch, dengan menggunakan data yang dikumpulkan dari proses operasi *plant* [18].

#### 2.4.2 Implementasi Model pada Kontrol Prediktif

Kontrol Prediktif atau biasa disebut *Model Predictive Control* merupakan sebuah metode yang berbasis pada teknik *receding horizon*. Model *neural network* akan memprediksi respon dari *plant* dalam jangka waktu yang ditentukan. Prediksi tersebut kemudian akan dilakukan optimalisasi untuk menentukan sinyal kontrol yang akan meminimalkan kriteria kinerja dari seluruh *horizon* yang telah ditentukan. Umumnya sebuah kontrol prediktif akan memiliki fungsi objektif sebagai berikut:

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 \quad (2.16)$$

dimana:

$N_1$  = *Horizon* prediksi maksimum

$N_2$  = *Horizon* prediksi minimum

$N_u$  = *Horizon* kontrol

$u'$  = Sinyal kontrol sementara/*tentative*


$y_r$  = Respon yang diinginkan (*set point*)

$y_m$  = Respon model *neural network* (*output prediction*)

$\rho$  = *Gain error*

$t$  = Waktu saat ini

Pengendali NNMPC terdiri dari dua blok sistem. Blok pertama merupakan model *neural network* dari *plant*, pada blok ini neural network yang telah dilakukan proses sistem identifikasi sebelumnya akan dapat memprediksi output dari plant  $y_m$  berdasarkan nilai input  $u$  dan keluaran plant  $y_p$  sebelumnya. Setelah itu  $y_m$  akan masuk ke dalam blok kedua.




**Gambar 2.13** Blok diagram NNMPC

Blok kedua merupakan blok dari optimasi. Pada blok optimasi lah yang akan menentukan nilai-nilai dari  $u'$  yang nantinya akan meminimalkan nilai fungsi objektif  $J$ , nilai minimal tersebut didapatkan dari selisih antara output prediksi  $y_m$  dengan nilai referensi yang ada  $y_r$ , kemudian nilai optimal dari  $u$  akan dijadikan *input* kepada *plant* [18].

## 2.5 Analisis Performansi Pengendalian

Analisis sistem pengendalian digunakan untuk menghasilkan respon sistem yang telah dirancang. Hasil dari bentuk analisa ini berupa nilai kualitatif. Jenis respon kontrol akan berbeda-beda berdasarkan orde dari sistem yang dikendalikan. Respon dinamik akan memiliki karakteristik yang berbeda berdasarkan jenis *plant* yang dikontrol. Sehingga respon dinamik setiap unit tergantung pada nilai masukan pada unit yang telah digunakan. Untuk jenis analisa respon dinamik dapat dilihat pada Gambar 2.14 berikut ini.



**Gambar 2.14** Analisa karakteristik performansi sistem [19]

Dari gambar diatas akan dapat dilakukan analisa performansi dari respon sistem. Dan untuk mengetahui nilai performansi dari nilai sistem maka perlu mendefinisikan nilai *error steady state*, *maximum overshoot*, *settling time*, maupun *Integral Absolute Error* (IAE). Masing-masing dari parameter tersebut dapat dicari dengan menganalisa respon sistem yang didapatkan dari hasil simulasi sebagai berikut ini :

a. *Maximum overshoot*

Nilai *maximum overshoot* adalah nilai puncak dari kurva respon yang diukur. Setiap perusahaan memiliki standarisasi tersendiri untuk nilai *maximum overshoot*. Dan untuk menentukan persamaan *maximum overshoot* dapat dihitung dengan menggunakan persamaan berikut ini.

$$MO = \frac{c(t_p) - c(\infty)}{c(\infty)} \times 100\% \quad (2.17)$$

b. *Settling Time*

*Settling time* adalah waktu yang dibutuhkan sistem untuk mencapai keadaan *set point*. Pada *settling time* terdapat presentase untuk menentukan nilai *settling time* yaitu sebesar  $\pm 2\%$  atau  $\pm 5\%$  dari nilai *set point*.

c. *Error steady state*


*Output* suatu sistem membutuhkan waktu untuk merespon perubahan ketika masukan sebuah sistem berubah secara tiba-tiba. Fasa peralihan ini kemudian akan berhenti pada nilai dikisaran *input/target* dimana selisih nilai akhir dengan target disebut *steady state error*.

$$ess = \lim_{t \rightarrow \infty} (r(t) - c(t)) \quad (2.18)$$

$$\%e = \frac{X_{ss} - Y_{ss}}{X_{ss}} \times 100\% \quad (2.19)$$


d. *Integral Absolute Error (IAE)*

Performa pengendalian dinilai optimal jika mampu meminimalkan akumulasi *error* (*integral error criteria*). Plot respon kesalahan untuk sistem yang khas ditunjukkan di bawah ini. Daerah yang terakumulasi saat kesalahan positif ditunjukkan dengan warna biru, dan daerah yang terakumulasi saat kesalahan negatif ditampilkan dalam warna merah. Area merah adalah negatif dan membatalkan beberapa area biru setiap siklus.



**Gambar 2.15** Respon kesalahan sistem

Salah satu metode analisa respon dari Gambar 2.15 adalah *Integral Absolute Error* (IAE), dimana membuat nilai absolut dari tiap kesalahan. Tanpa memperhatikan nilai positif atau negatif dari error yang dihasilkan, IAE membuat hasil integral dari error menjadi positif seperti pada gambar berikut.




**Gambar 2.16** Respon absolut kesalahan sistem


Analisa kinerja sistem ini dikenal sebagai Integral of Absolute value of The Error (IAE). Persamaan matematis IAE digambarkan di bawah ini.

$$IAE = \int_0^{\infty} |e(t)| dt = \int_0^{\infty} |r(t) - y(t)| dt \quad (2.20)$$

### BAB III METODOLOGI PENELITIAN

Diagram alir penelitian tugas akhir ini digambarkan pada Gambar 3.1 dengan penjelasan masing-masing langkah dijelaskan pada subbab berikut.





**Gambar 3.1** Diagram alir penelitian



### 3.1 Pengumpulan Data Komponen dan Konfigurasi Kolom Depropanizer

Pada penelitian ini proses yang digunakan dimodelkan menggunakan perangkat lunak Aspen HYSYS V8.8. Proses *depropanizer* yang dimodelkan pada perangkat lunak Aspen HYSYS dipilih karena terdapat penelitian sebelumnya yang juga mengacu pada referensi data yang sama [20].

Data yang dikumpulkan meliputi *depropanizer column internal data sheet* yang berisikan kondisi masing-masing *stream* serta komposisi masing-masing komponen pada setiap *stream*. Selain itu data *depropanizer column internal data sheet* juga berisikan data spesifikasi komponen-komponen yang melengkapi dari sistem kolom *depropanizer* seperti data spesifikasi *depropanizer column reboiler*, *depropanizer condenser*, dan *depropanizer reflux drum*.

Data *depropanizer column internal data sheet* ini diperoleh dari PT. PGN SAKA Pangkah Limited yang berada di Kabupaten Gresik, Jawa Timur. Data *depropanizer column internal data sheet* tersebut kemudian digunakan untuk simulasi proses pada perangkat lunak HYSYS. Berikut adalah data parameter dan komposisi komponen dari aliran *feed* kolom *depropanizer* pada *depropanizer column internal data sheet* yang dapat dilihat pada tabel 3.1. dan 3.2 di bawah ini.

**Tabel 3.1.** Data parameter utama pada aliran *feed* kolom *depropanizer*

Parameter	Nilai	Satuan
Temperatur <i>feed</i>	69,12	°C
Tekanan <i>feed</i>	16,4	barg
Laju aliran massa <i>feed</i>	26916	kg/h

**Tabel 3.2** Data komposisi komponen pada aliran *feed* kolom *depropanizer*

<b>Nama Komponen</b>	<b>Komposisi (% mole)</b>
H <sub>2</sub> S	0,000
CO <sub>2</sub>	0,010
Nitrogen	0,000
Methane	0,004
Ethane	2,599
Propane	57,111
i-Butane	14,582
n-Butane	15,574
i-Pentane	4,814
n-Pentane	2,959
n-Hexane	1,756
n-Heptane	0,382
n-Octane	0,157
n-Nonane	0,025
n-Decane	0,019
n-C11	0,006
n-C12	0,002

Dengan rincian tipe dan ukuran desain komponen-komponen kolom depropanizer yang dapat dilihat pada Tabel 3.3 hingga Tabel 3.6 di bawah ini.

**Tabel 3.3** Data spesifikasi *depropanizer column*

<b>Spesifikasi</b>	<b>Nilai</b>
<i>Size</i>	2000 x 37026 mm
<i>Diameter</i>	2 m
<i>Design Press</i>	22 barg
<i>Design Temp.</i>	135 / -29 °C
<i>Number of Tray</i>	50
<i>Internal Tray Type</i>	Valve

**Tabel 3.4** Data spesifikasi *depropanizer column reboiler*

Spesifikasi	Nilai	
Type	Kettle	
Design Duty	3321 kW	
	Shell	Tube
Design Press	22 barg	25 barg
Design Temp.	135 / -29 °C	250 / -29 °C

**Tabel 3.5** Data spesifikasi *depropanizer condenser*


Spesifikasi	Nilai
Type / Surface	Air Cooler / 1636 m <sup>2</sup>
Inlet / Outlet Temp	49 / 40.4 °C
Design Temp.	135 / -29 °C
Design Press.	22 barg
Duty	3452 kW
Motor Power	4 x 30 kW

**Tabel 3.6** Data spesifikasi *depropanizer reflux drum*

Spesifikasi	Nilai
Size	1900 x 5200 mm
Design Press	22 barg
Design Temp.	75 / -29 °C

### 3.2 Pemodelan Proses Kolom *Depropanizer* dengan HYSYS

Data tersebut kemudian digunakan untuk simulasi *steady state* kolom menggunakan perangkat lunak Aspen HYSYS. Dengan menggunakan Peng-Robinson *equation of state*, berikut merupakan tampilan simulasi kolom *depropanizer* saat kondisi *steady state*.




**Gambar 3.2** Tampilan *column environment* kolom depropanizer saat kondisi *steady state*

Dimana *feed* merupakan masukan kolom depropanizer. Sedangkan  $Q_C$  dan  $Q_R$  masing-masing merupakan *heat flow* dari kondenser dan reboiler.

**Tabel 3.7** Data *stream* kolom depropanizer

<i>Stream</i>	<i>Molar Flow Rate (kgmole/hr)</i>	<i>Fraction</i>	<i>Enthalpy (kJ/kgmole)</i>
<i>Feed</i>	525,14	0,5711	-127051,45
<i>To Condenser</i>	963,97	0,9556	-103481,56
<i>Reflux</i>	650,77	0,9556	-116248,70
<i>Top Product</i>	313,2	0,9556	-116248,70
<i>Flare</i>	0,000420	0,8987	-142419,86
<i>To Reboiler</i>	1009,56	0,00515	-142419,86
<i>Boilup</i>	797,61	0,00574	-126828,89
<i>Bottom Product</i>	211,94	0,00292	-144463,93
<i>Qreboiler</i>			12002337,13
<i>Qcondenser</i>			12307247,07

Sehingga kesetimbangan massa dan energi dari kolom dapat diperoleh dengan menggunakan persamaan 2.1 sampai dengan 2.8. Setelah itu kolom *depropanizer* diubah dari kondisi *steady state* ke kondisi *dynamic* dengan cara dilakukan *sizing* dan pemasangan kontroler. Data untuk melakukan *sizing* pada kolom *depropanizer*, kondenser, *reflux drum* dan *reboiler* berdasarkan pada Tabel 3.3, 3.4, 3.5 dan 3.6. Setelah kondisi kolom *depropanizer* dalam keadaan *dynamic* kemudian dilakukan pengendalian dengan cara diberi kotroler pada proses kolom *depropanizer*. Berikut merupakan tampilan simulasi kolom *depropanizer* saat kondisi *dynamic*.



**Gambar 3.3** Tampilan *column environment* kolom *depropanizer* saat kondisi *dynamic* beserta kontrolernya

Dengan rincian kontrol yang terpasang pada simulasi *dynamic* kolom *depropanizer* sebagai berikut.

**Tabel 3.8** Rincian kontrol yang terpasang pada kolom *depropanizer*

Kontroler	<i>Manipulated Variable</i>	<i>Process Variable</i>
PIC-100	<i>Top stage pressure</i>	Laju aliran panas kondenser
XIC-101	Fraksi propana pada distilat ( $X_D$ )	Laju aliran <i>reflux</i>
XIC-100	Fraksi propana pada <i>bottom product</i> ( $X_B$ )	Laju aliran <i>steam reboiler</i>
LIC-100	<i>Level reflux drum</i>	Laju aliran distilat
LIC-101	<i>Level reboiler</i>	Laju aliran <i>bottom product</i>

### 3.3 Validasi Model Proses Kolom Depropanizer


Validasi dari proses kolom *depropanizer* dilakukan dengan cara melakukan perbandingan antara nilai pada masing-masing *stream* dari hasil simulasi dan nilai pada masing-masing *stream* pada data *design*. Perbandingan tersebut dapat dilihat pada lampiran A.

### 3.4 Pengambilan Data *Open Loop* Kolom Depropanizer

Pada proses pengambilan data *open loop* ini terdapat dua variabel *input* yang diberikan kepada *plant* yaitu laju aliran *reflux* ( $L$ ) dan laju aliran panas pada *reboiler* ( $Q_r$ ), serta menghasilkan dua variabel *output* yaitu fraksi mol produk distilat ( $X_d$ ) dan fraksi bawah ( $X_b$ ). Sinyal input yang diberikan berupa sinyal APRBS (Amplitude Pseudo Random Binary Signal) bersifat random dan dapat diatur pada lebar pulsa dan amplitudonya.


APRBS adalah sinyal pemicu yang terbaik untuk mendapatkan karakteristik komplek proses yang diteliti dengan mengatur amplitudo dan lebar pulsa sinyal. Maka dengan penyiapan data input output yang terbaik pada penelitian ini, akan menghasilkan model yang akurat dan pada akhirnya akan menghasilkan sistem pengendalian yang baik [21].

Hasil data *open loop* dengan memberikan sinyal APRBS ke input  $L$  dan  $Q_r$  direkam menjadi pasangan data set *input-output plant* dan merupakan sinyal terbaik yang akan digunakan untuk proses pelatihan dan validasi *neural network*. Berikut ini merupakan data *open loop* yang digunakan untuk proses pelatihan *neural network* yang di ambil melalui *strip charts* pada perangkat lunak Aspen HYSYS.



**Gambar 3.4** Grafik *open loop* laju aliran refluks ( $L$ )

Pada pengambilan data *open loop* laju aliran refluks di diberikan sinyal input APRBS dengan amplitudo sinyal maksimum sebesar 26165.3 kg/h dan amplitudo minimum sebesar 23732 kg/h. Untuk lebar sinyalnya diberikan nilai maksimum 300 menit dan minimum 150 menit. Dari nilai-nilai tersebut maka sinyal APRBS akan meng-acak nilai pada *range* yang sudah diberikan, sinyal itu akan diberikan untuk mengganti nilai MV (*Manipulated Variable*) pada *control valve L* refluks sesuai dengan nilai yang ada.




**Gambar 3.5** Grafik *open loop* laju panas reboiler ( $Q_r$ )


Untuk pengambilan data *open loop* laju aliran panas reboiler ( $Q_r$ ) di diberikan sinyal *input* APRBS dengan amplitudo sinyal maksimum sebesar 12570900 kJ/h dan amplitudo minimum sebesar 8990910 kJ/h. Untuk lebar sinyalnya diberikan nilai maksimum 200 menit dan minimum 100 menit. Dari nilai-nilai tersebut maka sinyal APRBS akan meng-acak nilai pada *range* yang sudah diberikan, sinyal itu akan diberikan untuk mengganti nilai MV (*Manipulated Variable*) pada *control valve*  $Q_r$  reboiler sesuai dengan nilai yang ada.

Setelah memberikan sinyal *input* pada laju aliran refluks ( $L$ ) dan laju aliran panas reboiler ( $Q_r$ ) maka data perubahan output pada komposisi produk distilat ( $X_d$ ) dan komposisi produk bawah ( $X_b$ ) dapat diambil melalui *strip chart* seperti pada Gambar 3.10 dan 3.11 berikut.





**Gambar 3.6** Grafik *open loop* komposisi produk distilat ( $X_d$ )



**Gambar 3.7** Grafik *open loop* komposisi produk bawah ( $X_b$ )

Data yang sudah diperoleh kemudian dibagi menjadi 2 bagian yaitu data *training* (pelatihan) dan data validasi, dimana data yang digunakan untuk proses pelatihan lebih banyak dibandingkan proses validasi, dengan rincian 75% dari total keseluruhan data untuk pelatihan sedangkan sisanya 25% untuk validasi. Data-data


tersebut nantinya akan berfungsi sebagai masukan *neural network* dan juga sebagai validasi dari hasil keluaran *neural network*.

### **3.5 Perancangan Model Neural Network**

Pada penelitian ini pemodelan proses dilakukan dengan menggunakan *neural network* MLP (Multi Layer Perceptron) dengan struktur NNARX (Neural Network Auto Regressive eXternal input). Terdiri dari layer *input*, layer *hidden* dan layer *output* dengan fungsi aktivasi *hyperbolic tangent* pada *hidden neuron* dan *linear* pada *output neuron*.


Pada penelitian ini digunakan 2 buah model neural network Multi Input Single Output (MISO) daripada menggunakan 1 buah model Multi Input Multi Output (MIMO). Hal ini dikarenakan model neural network MISO akan menghasilkan akurasi yang lebih baik dari pada model neural network MIMO serta proses pelatihannya yang cenderung lebih cepat. Akurasi yang baik tersebut salah satunya dikarenakan model MISO mempunyai jumlah bobot diantara hidden dan output layer yang lebih sedikit bila dibandingkan dengan model MIMO dimana hal ini akan mengurangi banyaknya interaksi dan juga kompleksitas dari neural network itu sendiri [22].

Ke-2 model MISO yang digunakan pada penelitian ini dinamakan MISO1 dan MISO2. Berikut adalah gambar struktur neural network dengan jumlah layer dan fungsi aktivasi pada model MISO1 dan MISO2 yang digunakan pada penelitian ini.



**Gambar 3.8** Struktur model *neural network* MISO1

Pada model neural network MISO1 terdiri dari laju aliran refluks (L) dan laju aliran panas *reboiler* (Qr) sebagai masukan/input, serta komposisi propana pada produk distilat (Xd) sebagai keluaran/output.



**Gambar 3.9** Struktur model *neural network* MISO2

Sedangkan model neural network MISO2 terdiri dari laju aliran refluks (L) dan laju aliran panas *reboiler* (Qr) sebagai masukan/input, serta komposisi propana pada produk bawah (Xb) sebagai keluaran/output.

Pada saat awal pelatihan dengan bobot model diambil secara acak, maka  $Y$  dan  $Y_i$  akan menunjukkan harga yang berbeda pada keseluruhan data set pelatihan atau masih ada *error* ( $e$ ). *Error* ini adalah fungsi tujuan yang akan diminimisasi pada setiap iterasi atau epoch selama pelatihan menggunakan algoritma Levenberg Marquard dengan mengubah bobot  $W1$  dan  $W2$  pada neural network.

Validasi model yang telah dibuat terhadap plant dilakukan dengan memberikan input yang belum pernah dilatihkan kepada neural network. Baik tidaknya model *neural network* yang dibuat dapat dilihat dari *Mean Squared Error* (MSE) yang diperoleh sepanjang  $N$  sample. *Mean Squared Error* (MSE), dapat ditulis sebagai berikut :

$$MSE = \frac{\sum_{i=1}^n (y - y_i)^2}{N} \quad (3.1)$$

### 3.6 Perancangan Pengendali NN MPC

Untuk merancang pengendali *Neural Network Model Predictive Control* (NNMPC) dilakukan dengan menggunakan *toolbox* yang sudah ada pada Matlab Simulink. Terdapat dua tahapan utama yang harus dilakukan untuk dapat merancang pengendali NNMPC, yang pertama adalah tahap identifikasi sistem kemudian tahap kedua adalah tahap pengaturan parameter pengendalian NNMPC.

Pada tahap identifikasi sistem dibagi menjadi tiga bagian tahapan yaitu: tahap pengaturan arsitektur *neural network*, tahap pengaturan pengambilan data open loop dari model, serta tahap pelatihan model *neural network*. Dikarenakan pada penelitian ini menggunakan dua buah pengendalian yang terpisah maka untuk pengambilan data *open loop* pada perancangan NNMPC nya pun dibagi menjadi dua. Untuk pengendali NNMPC1 digunakan sinyal input APRBS (Amplitude Pseudo Random Binary Signal) yang diberikan pada laju aliran refluks (L) sedangkan nilai laju aliran panas *reboiler* (Qr) dibuat tetap pada nilai 10952600 kJ/h. Berikut

pada Tabel 3.9 adalah rincian dari parameter sinyal APRBS untuk pengendali NNMPC1.

**Tabel 3.9** Rincian parameter *input* APRBS untuk NNMPC1

Parameter	Nilai
<i>Sampling Interval</i> (sec)	1
<i>Training Samples</i> (n)	4000
<i>Maximum Plant Input</i> (kg/h)	26165
<i>Minimum Plant Input</i> (kg/h)	23732
<i>Maximum Interval Value</i> (sec)	300
<i>Minimum Interval Value</i> (sec)	150

Sedangkan untuk pengendali NNMPC2 digunakan sinyal input APRBS yang diberikan pada laju aliran panas *reboiler* ( $Q_r$ ) sedangkan nilai laju aliran refluks nya ( $L$ ) dibuat tetap pada nilai 24906 kg/h. Berikut pada Tabel 3.10 adalah rincian dari parameter sinyal APRBS untuk pengendali NNMPC2.

**Tabel 3.10** Rincian parameter *input* APRBS untuk NNMPC2

Parameter	Nilai
<i>Sampling Interval</i> (sec)	1
<i>Training Samples</i> (n)	4000
<i>Maximum Plant Input</i> (kJ/h)	12570900
<i>Minimum Plant Input</i> (kJ/h)	8990910
<i>Maximum Interval Value</i> (sec)	200
<i>Minimum Interval Value</i> (sec)	100

Tahap terakhir yaitu pengaturan parameter pengendalian NNMPC merupakan tahap untuk menentukan berapa nilai dari parameter pengendalian NNMPC atau sering disebut sebagai *tuning*. Beberapa parameter seperti nilai *Cost Horizon* ( $N_2$ ), *Control Horizon* ( $N_u$ ), *Control Weighting factor* ( $\rho$ ), dan *Search Parameter* ( $\alpha$ ) akan sangat berpengaruh terhadap performa dari pengendalian NNMPC. Untuk penelitian ini metode *tuning* yang digunakan adalah metode *trial and error*. Berikut pada Tabel 3.11

dan 3.12 adalah rincian nilai parameter NNMPC1 dan NNMPC2 yang telah didapatkan.

**Tabel 3.11** Rincian nilai parameter pengendali NNMPC1

<b>Parameter</b>	<b>Nilai</b>
<i>Cost Horizon</i> (N2)	25
<i>Control Horizon</i> (Nu)	15
<i>Control Weighting Factor</i> ( $\rho$ )	0.5
<i>Search Parameter</i> ( $\alpha$ )	0.01

**Tabel 3.12** Rincian nilai parameter pengendali NNMPC2

<b>Parameter</b>	<b>Nilai</b>
<i>Cost Horizon</i> (N2)	16
<i>Control Horizon</i> (Nu)	9
<i>Control Weighting Factor</i> ( $\rho$ )	0.4
<i>Search Parameter</i> ( $\alpha$ )	0.01

### 3.7 Pengujian Performansi Sistem dan Analisa

Uji performansi dilakukan untuk mengetahui kemampuan pengendali NNMPC dalam mengendalikan komposisi diltilat maupun produk bawah dari kolom *depropanizer*. Pengujian penformansi sistem dilakukan dengan melakukan uji perubahan set point serta uji gangguan kepada sistem berupa penambahan komposisi produk distilat dan produk bawah. Pengujian performansi tersebut diterapkan pada sistem dengan pengendai NNMPC dan pengendali PI dengan struktur *direct* sebagai pembanding.

Langkah berikutnya adalah dilakukan analisa pada grafik respon sistem yang diperoleh dengan membandingkan nilai parameter kestabilan berupa *settling time*, *maximum overshoot*, dan *error steadystate* serta perbandingan nilai Integral Absolute Error (IAE).

## **BAB IV**

### **HASIL DAN PEMBAHASAN**

#### **4.1 Pelatihan dan Validasi Model *Neural Network***

Proses pelatihan dan validasi model *neural network* dilakukan secara *offline*. Struktur *neural network* yang digunakan adalah NARX (Neural Network Auto Regressive, eXternal input) dengan 1 *input layer*, 1 *hidden layer* dan 1 *output layer*. Fungsi aktivasi yang digunakan adalah *tangent hyperbolic* pada *hidden layer* dan *linear* pada *output layer*. Sedangkan untuk metode pelatihan menggunakan algoritma pelatihan Levenberg Marquard. Hasil dari pemrosesan tersebut akan menampilkan nilai *Mean Squared Error* (MSE) pada tahap pelatihan dan validasi. Nilai MSE terkecil menunjukkan bahwa struktur tersebut adalah pemodelan terbaik yang dapat digunakan.


Pada penelitian ini dikembangkan 2 buah model *neural network* NARX *Multiple Input Single Output* (MISO) untuk memodelkan kolom *depropanizer*, yaitu MISO1 dan MISO2. Model *neural network* MISO1 terdiri dari laju aliran refluks (L) dan laju aliran panas *reboiler* (Qr) sebagai masukan, serta komposisi propana pada produk distilat (Xd) sebagai keluaran. Sedangkan model *neural network* MISO2 terdiri dari laju aliran refluks (L) dan laju aliran panas *reboiler* (Qr) sebagai masukan, serta komposisi propana pada produk bawah (Xb) sebagai keluaran.

##### **4.1.1 Pelatihan dan Validasi Model MISO1**

Pada pemodelan *neural network* MISO1 ini data yang diambil seluruhnya berjumlah 4000 sampel, dimana 75% data digunakan untuk pelatihan dan 25% data sisanya digunakan untuk validasi model *neural network* yang telah didapat. Maksimum *epoch* di *set* sebanyak 1000 kali iterasi dengan nilai *input delay* sebesar 2 detik.

Kemudian dilakukan variasi perubahan *hidden neurons* mulai dari 1 hingga 20 *hidden neurons* pada *hidden layer* untuk mendapatkan hasil pelatihan dan validasi terbaik. Berikut adalah hubungan antara nilai MSE dengan jumlah *hidden neurons* baik pada tahap pelatihan maupun validasi pada model MISO1 yang

ditunjukkan pada Gambar 4.1. Sedangkan untuk hasil pelatihan dan validasi model *neural network* MISO1 yang lengkap ada pada Lampiran B.1.




**Gambar 4.1** Grafik MSE vs *hidden neurons* tahap pelatihan dan validasi model MISO1


Dari grafik diatas menunjukkan bahwa secara umum proses pemodelan MISO1 menggunakan *neural network* ini berjalan dengan baik, dikarenakan nilai-nilai MSE baik pada tahap pelatihan maupun validasi didapatkan nilai yang kecil.

Kemudian dari grafik diatas juga dapat dilihat bahwa model *neural network* terbaik didapatkan pada *hidden neurons* 15 dengan rincian MSE tahap pelatihan sebesar  $3.53 \times 10^{-10}$  untuk fraksi mol produk distilat (Xd) dan nilai MSE tahap validasi nya sebesar  $4.45 \times 10^{-9}$  untuk fraksi mol produk distilat (Xd), nilai tersebut didapatkan pada *epoch* ke-151. Berikut adalah tampilan grafik performa *neural network* serta grafik respon *time-series* dari *neural network* dengan *hidden neurons* 15, ditunjukkan pada Gambar 4.2 dan 4.3.





**Gambar 4.2** Grafik performa model MISO1 dengan *hidden neurons* 15




**Gambar 4.3** Grafik respon *time-series* pelatihan dan validasi model MISO1 dengan *hidden neurons* 15

#### 4.1.2 Pelatihan dan Validasi Model MISO2

Pada pemodelan *neural network* MISO2 ini data yang diambil seluruhnya berjumlah 4000 sampel, dimana 75% data digunakan untuk pelatihan dan 25% data sisanya digunakan untuk validasi model *neural network* yang telah didapat. Maksimum *epoch* di *set* sebanyak 1000 kali iterasi dengan nilai *input delay* sebesar 2 detik.


Kemudian dilakukan variasi perubahan *hidden neurons* mulai dari 1 hingga 20 *hidden neurons* pada *hidden layer* untuk mendapatkan hasil pelatihan dan validasi terbaik. Berikut adalah hubungan antara nilai MSE dengan jumlah *hidden neurons* baik pada tahap pelatihan maupun validasi pada model MISO2 yang ditunjukkan pada Gambar 4.4. Sedangkan untuk hasil pelatihan dan validasi model *neural network* MISO1 yang lengkap ada pada Lampiran B.2.




**Gambar 4.4** Grafik MSE vs *hidden neurons* tahap pelatihan dan validasi model MISO2

Dari grafik diatas menunjukkan bahwa secara umum proses pemodelan MISO2 menggunakan *neural network* ini berjalan dengan baik, dikarenakan nilai-nilai MSE baik pada tahap pelatihan maupun validasi didapatkan nilai yang kecil.

Kemudian dari grafik diatas juga dapat dilihat bahwa model *neural network* terbaik didapatkan pada *hidden neurons* 19 dengan rincian MSE tahap pelatihan sebesar  $7.59 \times 10^{-10}$  untuk fraksi mol produk distilat ( $X_d$ ) dan nilai MSE tahap validasi nya sebesar  $1.40 \times 10^{-9}$  untuk fraksi mol produk distilat ( $X_d$ ), nilai tersebut didapatkan pada *epoch* ke-207. Berikut adalah tampilan grafik performa *neural network* serta grafik respon *time-series* dari *neural network* dengan *hidden neurons* 15, ditunjukkan pada Gambar 4.5 dan 4.6.




**Gambar 4.5** Grafik performa model MISO2 dengan *hidden neurons* 19




**Gambar 4.6** Grafik respon *time-series* pelatihan dan validasi model MISO2 dengan *hidden neurons* 19

#### 4.2 Pengujian Model *Neural Network*

Pengujian model *neural network* dilakukan dengan cara memberikan masukan data kepada model *neural network* yang telah dibuat, kemudian keluaran model tersebut dibandingkan dengan keluaran data yang ada sebelumnya. Data yang diberikan merupakan data *close loop* sebanyak 200 sampel dari model proses *depropanizer* yang berbeda dengan data pada proses pelatihan dan validasi. Hasil dari pengujian performa model *neural network* kemudian ditampilkan dalam bentuk nilai *Mean Squared Error* (MSE). Berikut adalah hasil dari pengujian model *neural network* baik model MISO1 dan model MISO2 yang ditampilkan pada Gambar 4.7 dan Gambar 4.8.



**Gambar 4.7** Grafik respon time-series pengujian model MISO1



**Gambar 4.8** Grafik respon time-series pengujian model MISO2

Setelah dilakukan tahap pengujian model *neural network* MISO1 dan MISO2 didapatkan nilai MSE berturut-turut sebesar  $9.24 \times 10^{-10}$  untuk fraksi mol produk distilat ( $X_d$ ) dan  $4.99 \times 10^{-9}$  untuk fraksi mol produk bawah ( $X_b$ ). Hasil pengujian model yang didapatkan tersebut merupakan nilai yang sangat baik dikarenakan nilai MSE nya yang sangat kecil dan sudah mendekati nilai 0.

### 4.3 Perancangan Pengendali NN MPC

Dalam perancangan pengendali *Neural Network Model Predictive Control* (NNMPC) dilakukan dengan menggunakan MATLAB Simulink. Dikarenakan NN MPC yang ada pada MATLAB hanya dapat menangani pengendalian SISO, maka pada perancangan pengendalian ini dibagi menjadi 2 bagian yaitu: NN MPC1 untuk mengendalikan produk distilat ( $X_d$ ) dengan memanipulasi laju aliran refluks ( $L$ ) dan NN MPC2 untuk mengendalikan produk bawah ( $X_b$ ) dengan memanipulasi laju panas *reboiler* ( $Q_r$ ). Dalam merancang pengendali NN MPC terdapat 2 tahapan utama, yang pertama adalah indentifikasi sistem kemudian tahap kedua adalah menentukan parameter pengendalian NN MPC.

#### 4.3.1 Perancangan NN MPC1

Tahap indentifikasi sistem untuk NN MPC1 dimulai dengan pengambilan data input-output pada *plant*/model yang akan di kendalikan. Sinyal *input* yang diberikan merupakan sinyal APRBS yang dapat diatur amplitudo dan lebar sinyalnya. Dari parameter yang sudah diperoleh pada subbab sebelumnya maka didapatkan data input-output seperti pada Gambar 4.9 berikut.

**Gambar 4.9** Data input-output dari *plant* yang dikendalikan oleh NN MPC1

Setelah didapatkan data input-output maka tahap identifikasi sistem ini harus dilanjutkan dengan tahap pelatihan model *neural network*. Pada tahap pelatihan *neural network* ini maksimum *epoch* di-set sebesar 1000 iterasi serta salah satu parameter arsitektur *neural network* yaitu *delay input* di-set sebesar 2 detik. Kemudian dilakukan variasi pada jumlah *hidden neurons* mulai dari 1 hingga 10 *hidden neurons*.

**Tabel 4.1** Hasil variasi *hidden neurons* untuk pengendali NNMPC1


<i>Hidden Neurons</i>	<b>MSE Pelatihan</b>	<b>MSE Validasi</b>
1	$3.29 \times 10^{-5}$	$1.02 \times 10^{-5}$
2	$4.00 \times 10^{-8}$	$2.87 \times 10^{-8}$
3	$2.28 \times 10^{-8}$	$3.59 \times 10^{-8}$
4	$1.73 \times 10^{-8}$	$3.81 \times 10^{-8}$
5	$4.47 \times 10^{-9}$	$5.11 \times 10^{-9}$
6	$9.03 \times 10^{-9}$	$1.12 \times 10^{-8}$
7	$4.62 \times 10^{-10}$	$2.48 \times 10^{-10}$
8	$3.26 \times 10^{-9}$	$2.77 \times 10^{-9}$
9	$7.28 \times 10^{-10}$	$1.10 \times 10^{-9}$
10	$2.70 \times 10^{-10}$	$3.93 \times 10^{-10}$

Dari tabel diatas dapat dilihat bahwa model *neural network* terbaik pada tahap pelatihan didapatkan pada *hidden neurons* 10 dengan rincian MSE sebesar  $2.70 \times 10^{-10}$  untuk fraksi mol produk distilat (Xd), dengan nilai MSE tahap validasi nya sebesar  $3.93 \times 10^{-10}$  untuk fraksi mol produk distilat (Xd). Model *neural network* inilah yang digunakan sebagai model dalam pengendali NNMPC1.

#### 4.3.2 Perancangan NNMPC2

Tahap identifikasi sistem untuk NNMPC2 dimulai dengan pengambilan data input-output pada *plant*/model yang akan di kendalikan. Sinyal *input* yang diberikan merupakan sinyal APRBS yang dapat diatur amplitudo dan lebar sinyalnya. Dari parameter yang sudah diperoleh pada subbab sebelumnya maka didapatkan data input-output seperti pada Gambar 4.10 berikut.





**Gambar 4.10** Data input-output dari *plant* yang dikendalikan oleh NN MPC2

Setelah didapatkan data input-output maka tahap identifikasi sistem ini harus dilanjutkan dengan tahap pelatihan model *neural network*. Pada tahap pelatihan *neural network* ini maksimum *epoch* di-set sebesar 1000 iterasi serta salah satu parameter arsitektur *neural network* yaitu *delay input* di-set sebesar 2 detik. Kemudian dilakukan variasi pada jumlah *hidden neurons* mulai dari 1 hingga 10 *hidden neurons*.


**Tabel 4.2** Hasil variasi *hidden neurons* untuk pengendali NNMPC2

<i>Hidden Neurons</i>	MSE Pelatihan	MSE Validasi
1	$7.00 \times 10^{-7}$	$4.88 \times 10^{-7}$
2	$6.90 \times 10^{-8}$	$4.49 \times 10^{-8}$
3	$7.72 \times 10^{-8}$	$5.12 \times 10^{-8}$
4	$3.66 \times 10^{-8}$	$2.52 \times 10^{-8}$
5	$6.66 \times 10^{-8}$	$6.27 \times 10^{-8}$
6	$1.70 \times 10^{-8}$	$3.10 \times 10^{-8}$
7	$6.66 \times 10^{-9}$	$1.13 \times 10^{-8}$
8	$1.23 \times 10^{-8}$	$5.57 \times 10^{-9}$
9	$9.24 \times 10^{-9}$	$2.07 \times 10^{-8}$
10	$6.19 \times 10^{-9}$	$4.86 \times 10^{-9}$

Dari tabel diatas dapat dilihat bahwa model *neural network* terbaik pada tahap pelatihan didapatkan pada *hidden neurons* 10 dengan rincian MSE sebesar  $6.19 \times 10^{-9}$  untuk fraksi mol produk bawah (Xb), dengan nilai MSE tahap validasi nya sebesar  $4.86 \times 10^{-9}$  untuk fraksi mol produk bawah (Xb). Model *neural network* inilah yang digunakan sebagai model dalam pengendali NNMPC2.

#### 4.4 Uji Pengendali NNMPC

Pada penelitian ini nilai dari parameter pengendali NNMPC ditentukan menggunakan metode *trial and error*. Sedangkan untuk penentuan parameter PI sebagai pembanding menggunakan fitur *autotuning* pada MATLAB Simulink. Uji pertama dilakukan dengan memberikan *set point* tertentu pada sistem pengendali yaitu sebesar 0.95 untuk komposisi produk distilat (Xd). Simulasi dilakukan selama 1500 detik lalu nilai dari respon *plant* direkam dan didapatkan hasil sebagai berikut.



**Gambar 4.11** Plot respon pengendalian NN MPC1 dan PI1 pada  $X_d$  dengan set point 0.95

Grafik berwarna biru menunjukkan *set point* yaitu sebesar 0.95, grafik warna jingga merupakan variabel proses dari pengendali NN MPC1 sedangkan warna ungu merupakan variabel proses dari pengendali PI1. Kemudian dari grafik diatas dilakukan analisis parameter performansi pengendalian, didapatkan hasil sebagai berikut.

**Tabel 4.3** Parameter performansi hasil uji  $X_d$


	NN MPC1	PI1
<i>Settling Time</i> (detik)	531	1096
<i>Error Steady State</i> (%)	0	0
<i>Maximum Overshoot</i> (%)	2.5579	1.1053
IAE	5.4306	9.6988

Dari tabel diatas didapatkan nilai parameter pengendalian pada kedua jenis pengendalian yang cukup baik. Untuk parameter *settling time* pada pengendali NN MPC1 didapatkan perbedaan yang cukup signifikan yang bernilai 531 detik jauh lebih kecil apabila dibandingkan dengan PI1 yang memiliki nilai sebesar 1096 detik. Pada *error steady state* didapatkan nilai yang sama pada

kedua pengendali baik NNMPC1 maupun PI1 yaitu 0%. Kemudian untuk *maximum overshoot* pada NNMPC1 didapatkan nilai yang kurang baik dikarenakan memiliki nilai yang lebih besar yaitu sebesar 2.5579% dibandingkan dengan PI1 sebesar 1.1053%.

Secara keseluruhan uji perbandingan suatu sistem pengendali dapat dilihat dari nilai *Integral Absolute Error* (IAE) nya. Pada table diatas terlihat bahwa pengendali NNMPC1 memiliki nilai IAE yang lebih kecil yaitu sebesar 5.4306 dibandingkan dengan PI1 sebesar 9.6988. Hal ini menandakan bahwa pengendali NNMPC1 memiliki performa lebih baik dari PI1 dalam mengendalikan komposisi produk distilat (Xd).

Kemudian uji kedua kemudian dilakukan dengan memberikan set point tertentu pada sistem yaitu sebesar 0.015 untuk komposisi produk bawah (Xb). Simulasi dilakukan selama 1500 detik lalu nilai dari respon *plant* direkam dan didapatkan hasil sebagai berikut.



**Gambar 4.12** Plot respon pengendalian NNMPC2 dan PI2 pada Xb dengan set point 0.015

Grafik berwarna biru menunjukkan *set point* yaitu sebesar 0.015, grafik warna jingga merupakan variabel proses dari pengendali NNMPC2 sedangkan warna ungu merupakan variabel

proses dari pengendali PI2. Kemudian dari grafik diatas dilakukan analisis parameter performansi pengendalian, didapatkan hasil sebagai berikut.

**Tabel 4.4** Parameter performansi hasil uji Xb

	<b>NNMPC2</b>	<b>PI2</b>
<i>Settling Time</i> (detik)	136	828
<i>Error Steady State</i> (%)	0	0
<i>Maximum Overshoot</i> (%)	0	36
IAE	4.6681	9.3838

Dari tabel diatas didapatkan nilai parameter pengendalian pada kedua jenis pengendalian yang cukup baik. Untuk parameter *settling time* pada pengendali NNMPC2 didapatkan perbedaan yang cukup signifikan yang bernilai 136 detik jauh lebih kecil apabila dibandingkan dengan PI2 yang memiliki nilai sebesar 828 detik. Pada *error steady state* didapatkan nilai yang sama pada kedua pengendali baik NNMPC2 maupun PI2 yaitu 0%. Kemudian untuk *maximum overshoot* pada NNMPC2 didapatkan nilai yang sangat baik dikarenakan memiliki nilai yang jauh lebih kecil yaitu sebesar 0% dibandingkan dengan PI2 sebesar 36%.

Secara keseluruhan uji perbandingan suatu sistem pengendali dapat dilihat dari nilai *Integral Absolute Error* (IAE) nya. Pada table diatas terlihat bahwa pengendali NNMPC2 memiliki nilai IAE yang lebih kecil yaitu sebesar 4.6681 dibandingkan dengan PI2 sebesar 9.3838. Hal ini menandakan bahwa pengendali NNMPC2 memiliki performa lebih baik dari PI2 dalam mengendalikan komposisi produk bawah (Xb).

Nilai IAE pada kedua pengendali yang lebih kecil menandakan bahwa pengendali NNMPC mampu meminimalisir *error* yang ada baik pada komposisi produk distilat (Xd) maupun komposisi bawah (Xb) dengan lebih baik. Hal ini sangat penting dikarenakan baik atau buruknya pengendalian pada komposisi kolom *depropanizer* akan berpengaruh terhadap proses selanjutnya yaitu pada kolom *debutanizer*. Apabila keluaran produk bawah dari kolom *depropanizer* yang juga merupakan *feed* untuk *debutanizer*

memiliki komposisi yang tidak sesuai dengan yang sudah ditentukan, maka *error* pada komposisi *feed* akan menjadi gangguan/*disturbance* pada proses kolom *debutanizer*.

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Berdasarkan hasil analisis yang telah dilakukan, kesimpulan dari tugas akhir ini adalah sebagai berikut:

1. Telah dibuat suatu model *neural network* dari kolom *depropanizer* dengan menggunakan 2 buah model *Multi Input Single Output* (MISO).
2. Untuk model *neural network* MISO1 didapatkan MSE pelatihan dan validasi sebesar  $3.53 \times 10^{-10}$  dan  $4.45 \times 10^{-9}$  untuk fraksi mol produk distilat (Xd). Sedangkan pada model *neural network* MISO2 didapatkan MSE pelatihan dan validasi sebesar  $7.59 \times 10^{-10}$  dan  $1.40 \times 10^{-9}$  untuk fraksi mol produk bawah (Xb).
3. Model *neural network* telah mampu memodelkan suatu kolom *depropanizer* dengan baik dimana didapatkan MSE pengujian sebesar  $9.24 \times 10^{-10}$  untuk fraksi mol produk distilat (Xd) dan  $4.99 \times 10^{-9}$  untuk fraksi mol produk bawah (Xb).
4. Pengendali NNMPCC memiliki performansi yang cukup baik ditunjukkan dengan nilai IAE yang lebih kecil dari pengendali PI yaitu sebesar 5.4306 untuk produk distilat (Xd) dan 4.6681 untuk produk bawah (Xb).

#### **5.2 Saran**

Dari hasil tugas akhir ini dapat diberikan beberapa saran untuk pengembangan penelitian selanjutnya antara lain :

1. Untuk mengendalikan suatu sistem yang MIMO (*Multi Input Multi Output*) akan lebih baik apabila pengendali NNMPCC yang MIMO pula.
2. Untuk menghasilkan pengendalian NNMPCC yang lebih baik apabila menggunakan metode tuning yang bersifat analitis.

*“Halaman ini sengaja dikosongkan”*



## DAFTAR PUSTAKA

- [1] Kementrian ESDM. 2012. “Kajian *Supply Demand Energy*”. Pusat Data dan Informasi Energi dan Sumber Daya Mineral Kementrian Energi dan Sumber Daya Mineral.
- [2] Enweremadu, C. 2012. “*Energy Conservation in Ethanol-Water Distillation Column with Vapour Recompression Heat Pump, Distillation-Advances from Modelling to Applications*”. South Africa: Intech.
- [3] Riggs, James. B. 2000. “*Comparison Of Advanced Distillation Control Methods*”. Texas Tech University. *Final Technical Report* April 1994 March 1999.
- [4] Jaya, A., & Kolmetz, K. 2013. LPG Unit (*Engineering Design Guideline*). Johor Bahru: KLM Technology Group.
- [5] Agachi, Paul Serban. 2006. *Model Based Control*. German : WILEY-VCH Verlag GmbH.
- [6] Tham, M. T. 1999. “*Multivariable Control : An Introduction To Decoupling Control*”. University of Newcastle.
- [7] Biyanto, TR. 2004. “Pengendalian Kolom Distilasi Tunggal Sistem Biner dengan Internal Model Kontrol (IMC) Berbasis *Neurofuzzy*”. Tesis. Teknik Kimia. Fakultas Teknologi Industri. Institut Teknologi Sepuluh Nopember Surabaya.
- [8] Maciejowski, J. M. 2002. “*Predictive Control with Constraints*”. Prentice Hall. Pearson Education. New Jersey.
- [9] Biyanto, TR. “Jaringan Syaraf Tiruan untuk Model Prediktif Kontrol”. Teknik Fisika. Fakultas Teknologi Industri. Institut Teknologi Sepuluh Nopember Surabaya.
- [10] I. Rechenberg, *Evolutionstrategie '94*. Frommann-Holzboog, Stuttgart, 1994.
- [11] N. Hansen, D. V. Arnold, and A. Auger, ES, April, 2013
- [12] RWTUV. 2005. “*Distillation: Principles, Control & Troubleshooting*”. Dubai.
- [13] Manimaran, M., Arumugam, A., Balasubramanian, G., & Ramkumar, K. (2013). Optimization and composition control of distillation column using MPC. *International Journal of Engineering and Technology*, 5(2), 1224–1230.

- [14] Seborg, D. E., Edgar, T. F., & Mellichamp, D. a. (2011). Model Predictive Control. *Process Dynamics and Control*, 414–438.
- [15] Sbarbaro, D. Hunt, K.J, and Zbikowski, Rm, 1992, *Neural Networks for Control Systems-A Survey*, Automatica, 28(6), 1083-1112.
- [16] Cybenko G. 1989. “*Approximation by Super-position of A Sigmoid Function*”. Mathematics of Control. Signal and Systems, Vol. 2(4), 303-314.
- [17] Norgaard, M., Ravn, O., Paulsen, N.K., Hansen, L.K., 2000. “*Neural Network fo Modelling and Control for Dynamic System*”. Springer. London.
- [18] <https://www.mathworks.com/help/nnet/ug/design-neural-network-predictive-controller-in-simulink.html>. “*Design Neural Network Predictive Controller in Simulink*”.
- [19] Ogata, K. (2002). Transient And Steady State Response Analyses. In K. Ogata, *Modern Control Engineering (4th Edition)* (p. 230). St Paul, Minnesota: Aeizh.
- [20] Mouldy. 2016. “Optimasi Kualitas Produk Kolom Depropanizer Melalui Perubahan *Set Point* Pada Laju Aliran Reflux dan *Steam Reboiler*”. Teknik Fisika. Fakultas Teknologi Industri. Institut Teknologi Sepuluh Nopember Surabaya.
- [21] Nelles O, Isermann R, 1996, *Basis Function Networks for Interpolation of Local Linear Models*, Proc.of 35 th Conference on Decision and Control, Kobe, Japan
- [22] Fi, John Chang. 2007. “*Multi-step-ahead flood forecasting by neural networks*”. Department of Bioenvironmental Systems Engineering, National Taiwan University. Taipei. Taiwan.

## LAMPIRAN A. Hasil Validasi Data Proses

**Tabel A.1** Validasi data aliran *feed*

<b>Parameter</b>	<b>Data <i>Design</i></b>	<b>Data Simulasi</b>	<b><i>Error</i> (%)</b>
Temperatur	69,12 °C	69,12 °C	0
Tekanan	16,4 barg	16,4 barg	0
Laju aliran massa	26916 kg/h	26,916 kg/h	0
<b>Nama Komponen</b>	<b>Komposisi</b>		
H <sub>2</sub> S	0	0	0
CO <sub>2</sub>	0,0001	0,0001	0
Nitrogen	0	0	0
Methane	0,00004	0,00004	0
Ethane	0,02599	0,02599	10
Propane	0,57111	0,57111	0
i-Butane	0,14582	0,14582	0
n-Butane	0,15574	0,15574	0
i-Pentane	0,04814	0,04814	0
n-Pentane	0,02959	0,02959	0
n-Hexane	0,01756	0,01756	0
n-Heptane	0,00382	0,00382	0
n-Octane	0,00157	0,00157	0
n-Nonane	0,00025	0,00025	0
n-Decane	0,00019	0,00019	0
n-C11	0,00006	0,00006	0
n-C12	0,00002	0,00002	0

**Tabel A.2** Validasi data aliran *reflux*

<b>Parameter</b>	<b>Data Design</b>	<b>Data Simulasi</b>	<b>Error (%)</b>
Temperatur	45,63 °C	45,89 °C	0,58
Tekanan	16,2 barg	16,2 barg	0
Laju aliran massa	28305 kg/h	28303,58 kg/h	0,01
<b>Nama Komponen</b>	<b>Komposisi</b>		
H <sub>2</sub> S	0	0	0
CO <sub>2</sub>	0,0001	0,00016767	6,85
Nitrogen	0	0	0
Methane	0,00004	6,70676E-05	16,17
Ethane	0,02599	0,043577469	0,19
Propane	0,57111	0,955609334	0,67
i-Butane	0,14582	0,00057787	91,48
n-Butane	0,15574	5,90048E-07	98,82
i-Pentane	0,04814	0	0
n-Pentane	0,02959	0	0
n-Hexane	0,01756	0	0
n-Heptane	0,00382	0	0
n-Octane	0,00157	0	0
n-Nonane	0,00025	0	0
n-Decane	0,00019	0	0
n-C11	0,00006	0	0
n-C12	0,00002	0	0

**Tabel A.3** Validasi data aliran *boilup*

<b>Parameter</b>	<b>Data Design</b>	<b>Data Simulasi</b>	<b>Error (%)</b>
Temperatur	110,44 °C	45,89 °C	0,97
Tekanan	16,4 barg	16,4 barg	0
Laju aliran massa	47089 kg/h	48070,15 kg/h	2,08
<b>Nama Komponen</b>	<b>Komposisi</b>		
H <sub>2</sub> S	0	0	0
CO <sub>2</sub>	0	0	0
Nitrogen	0	0	0
Methane	0	0	0
Ethane	0	0	0
Propane	0,02943	0,005744055	80,48
i-Butane	0,43043	0,44656298	3,75
n-Butane	0,40349	0,408711885	1,29
i-Pentane	0,07768	0,078919899	1,60
n-Pentane	0,04248	0,043201909	1,70
n-Hexane	0,01421	0,014521279	2,19
n-Heptane	0,00179	0,001831936	2,34
n-Octane	0,00043	0,000440755	2,50
n-Nonane	0,00004	0,0000418	4,50
n-Decane	0,00002	0,0000191	4,50
n-C11	0	0	0
n-C12	0	0	0

**Tabel A.4** Validasi data aliran *to condenser*

<b>Parameter</b>	<b>Data Design</b>	<b>Data Simulasi</b>	<b>Error (%)</b>
Temperatur	48,78 °C	4,29 °C	1,01
Tekanan	16,2 barg	16,2 barg	0
Laju aliran massa	41927 kg/h	41925 kg/h	0
<b>Nama Komponen</b>	<b>Komposisi</b>		
H <sub>2</sub> S	0,00001	0	100
CO <sub>2</sub>	0,00018	0,0002	6,85
Nitrogen	0	0	0
Methane	0,00008	0,000067	16,25
Ethane	0,04366	0,04357	0,21
Propane	0,94925	0,9556	0,67
i-Butane	0,00678	0,00057	91,59
n-Butane	0,00005	0,0000005	98,82
i-Pentane	0	0	0
n-Pentane	0	0	0
n-Hexane	0	0	0
n-Heptane	0	0	0
n-Octane	0	0	0
n-Nonane	0	0	0
n-Decane	0	0	0
n-C11	0	0	0
n-C12	0	0	0

**Tabel A.5** Validasi data aliran *to reboiler*

<b>Parameter</b>	<b>Data Design</b>	<b>Data Simulasi</b>	<b>Error (%)</b>
Temperatur	104,53 °C	106,19 °C	1,58
Tekanan	16,4 barg	16,4 barg	0
Laju aliran massa	60383 kg/h	61364,40 kg/h	1,63
<b>Nama Komponen</b>	<b>Komposisi</b>		
H <sub>2</sub> S	0	0	0
CO <sub>2</sub>	0	0	0
Nitrogen	0	0	0
Methane	0	0	0
Ethane	0	0	0
Propane	0,02636	0,00515	80,46
i-Butane	0,41337	0,42848	3,66
n-Butane	0,39949	0,40392	1,11
i-Pentane	0,08646	0,08739	1,08
n-Pentane	0,049	0,04952	1,07
n-Hexane	0,02042	0,02061	0,92
n-Heptane	0,00342	0,00343	0,42
n-Octane	0,00116	0,00116	0,42
n-Nonane	0,00017	0,00016	4,07
n-Decane	0,00011	0,00011	3,58
n-C11	0,00003	0,00003	0
n-C12	0,00001	0,000011	10

**Tabel A.6** Validasi data aliran *bottom product*

<b>Parameter</b>	<b>Data Design</b>	<b>Data Simulasi</b>	<b>Error (%)</b>
Temperatur	110,44 °C	110,6 °C	0,13
Tekanan	16,4 barg	16,4 barg	0,23
Laju aliran massa	13,294 kg/h	13274,3 kg/h	0,15
<b>Nama Komponen</b>	<b>Komposisi</b>		
H <sub>2</sub> S	0	0	0
CO <sub>2</sub>	0	0	0
Nitrogen	0	0	0
Methane	0	0	0
Ethane	0	0	0
Propane	0,015	0,0029	80,56
i-Butane	0,3503	0,3605	2,90
n-Butane	0,38469	0,3859	0,31
i-Pentane	0,11893	0,1193	0,29
n-Pentane	0,0731	0,0733	0,30
n-Hexane	0,04337	0,0435	0,32
n-Heptane	0,00944	0,0095	0,26
n-Octane	0,00388	0,0039	0,26
n-Nonane	0,00063	0,0006	1,68
n-Decane	0,00046	0,0005	2,34
n-C11	0,00015	0,0001	0,89
n-C12	0,00004	0,00004	0,00



## LAMPIRAN B. Hasil Pelatihan dan Validasi Model *Neural Network*

**Tabel B.1** Hasil pelatihan model *neural network* MISO1

<i>Hidden Neurons</i>	<b>MSE Pelatihan</b>	<b>MSE Validasi</b>	<i>Epoch</i>
1	8.03944E-10	1.0193E-09	710
2	6.74046E-10	6.81917E-10	128
3	6.41708E-10	1.03089E-09	180
4	5.34289E-10	8.77217E-10	93
5	6.21116E-10	5.71461E-10	209
6	8.2948E-10	3.36434E-09	109
7	5.71116E-10	6.8549E-10	226
8	6.36419E-10	5.71905E-10	164
9	6.40721E-10	6.73495E-10	44
10	7.9048E-10	7.29214E-10	91
11	7.4255E-10	9.12538E-10	176
12	6.65146E-10	1.30375E-09	140
13	7.26211E-10	3.93846E-09	111
14	4.78998E-10	1.73515E-07	104
15	3.5327E-10	4.44507E-09	151
16	5.74627E-10	6.53155E-10	248
17	7.14088E-10	1.13989E-09	171
18	8.66512E-10	6.52849E-08	78
19	7.47972E-10	3.04976E-08	181
20	4.80119E-10	1.53232E-09	80

**Tabel B.2** Hasil pelatihan model *neural network* MISO2

<i>Hidden Neurons</i>	<b>MSE Pelatihan</b>	<b>MSE Validasi</b>	<i>Epoch</i>
1	1.51789E-08	6.68331E-08	1000
2	1.79689E-09	3.47694E-09	847
3	2.47125E-09	2.19148E-09	302
4	1.90557E-09	2.30067E-09	196
5	2.18277E-09	3.27461E-09	247
6	1.90156E-09	1.95164E-09	258
7	1.50791E-09	2.48909E-09	264
8	1.24E-09	9.85385E-09	221
9	1.1906E-09	1.32478E-09	304
10	1.0556E-09	1.8441E-09	318
11	1.04649E-09	1.41752E-09	231
12	1.55317E-09	3.69477E-08	183
13	1.19221E-09	2.08593E-08	416
14	8.05213E-10	1.77945E-09	361
15	9.18068E-10	1.98758E-09	453
16	8.43199E-10	1.26144E-08	247
17	1.69679E-09	3.01762E-09	346
18	1.24364E-09	5.10495E-08	491
19	7.59783E-10	1.40018E-09	207
20	9.46659E-10	2.96885E-09	214

## LAMPIRAN C. Hasil Testing Model Neural Network

**Tabel C.1** Tabel perhitungan *error* pengujian model MISO1

No	L	Qr	Xd	Xd Pred	Error	Error <sup>2</sup>
1	24899.7	10068000	0.9512 87	0.9515 00575	- 0.00021 3575	4.56142 E-08
2	24897.1	9791540	0.9519 44	0.9520 70347	- 0.00012 6347	1.59635 E-08
3	24894.5	9544180	0.9524 78	0.9525 72246	- 9.42462 E-05	8.88235 E-09
4	24892	9316560	0.9529 01	0.9529 78142	- 7.71418 E-05	5.95086 E-09
5	24889.7	9104790	0.9532 2	0.9532 85024	- 6.50237 E-05	4.22808 E-09
6	24887.6	8906520	0.9534 4	0.9534 96023	- 5.6023 E-05	3.13857 E-09
7	24885.6	8719380	0.9535 66	0.9536 14376	- 4.83762 E-05	2.34026 E-09
8	24883.8	8542970	0.9536 03	0.9536 44963	- 4.19626 E-05	1.76086 E-09
9	24882.3	8382870	0.9535 55	0.9535 92582	- 3.75818 E-05	1.41239 E-09
10	24881	8244120	0.9534 25	0.9534 60105	- 3.51053 E-05	1.23238 E-09
11	24880	8129510	0.9532 16	0.9532 49434	- 3.3434 E-05	1.11783 E-09
12	24879.3	8039900	0.9529 32	0.9529 63417	- 3.1417 E-05	9.87025 E-10
13	24878.9	7977630	0.9525 74	0.9526 0691	- 3.29099 E-05	1.08306 E-09

14	24878.9	7945270	0.9521 48	0.9521 77901	- 2.99008 E-05	8.9406E- 10
15	24879.2	7945150	0.9516 59	0.9516 87154	- 2.81539 E-05	7.92641 E-10
16	24879.8	7979290	0.9511 14	0.9511 38652	- 2.46524 E-05	6.07742 E-10
17	24880.8	8048980	0.9505 24	0.9505 41286	- 1.72864 E-05	2.98819 E-10
18	24882.1	8154400	0.9499 01	0.9499 099	- 8.89976 E-06	7.92057 E-11
19	24883.7	8294520	0.9492 62	0.9492 57482	4.51786 E-06	2.04111 E-11
20	24885.5	8467420	0.9486 24	0.9486 05913	1.8087 E-05	3.27141 E-10
21	24887.5	8670340	0.9480 08	0.9479 72316	3.56836 E-05	1.27332 E-09
22	24889.7	8900130	0.9474 33	0.9473 81768	5.12317 E-05	2.62469 E-09
23	24891.8	9155840	0.9469 19	0.9468 51682	6.73176 E-05	4.53166 E-09
24	24894	9432640	0.9464 84	0.9464 03634	8.03664 E-05	6.45876 E-09
25	24896	9726650	0.9461 44	0.9460 54182	8.98177 E-05	8.06721 E-09
26	24897.9	10040100	0.9459 11	0.9458 17732	9.32682 E-05	8.69896 E-09
27	24899.5	10374600	0.9457 91	0.9457 01621	8.93787 E-05	7.98856 E-09
28	24900.9	10719500	0.9457 84	0.9457 0238	8.16196 E-05	6.66176 E-09
29	24901.9	11061600	0.9458 89	0.9458 09039	7.99607 E-05	6.39371 E-09
30	24902.6	11391400	0.9460 97	0.9460 21479	7.55211 E-05	5.70344 E-09
31	24902.9	11700900	0.9463 97	0.9463 27706	6.9294 E-05	4.80165 E-09
32	24903	11983400	0.9467 71	0.9467 15698	5.53024 E-05	3.05835 E-09

33	24902.7	12233500	0.9471 98	0.9471 59541	3.84592 E-05	1.47911 E-09
34	24902.1	12447600	0.9476 56	0.9476 34515	2.14847 E-05	4.61591 E-10
35	24901.4	12623300	0.9481 22	0.9481 17542	4.45752 E-06	1.98695 E-11
36	24900.5	12760000	0.9485 73	0.9485 85134	- 1.2134 E-05	1.47234 E-10
37	24899.6	12858200	0.9489 92	0.9490 15136	- 2.31356 E-05	5.35254 E-10
38	24898.6	12919600	0.9493 66	0.9493 97158	- 3.11581 E-05	9.70827 E-10
39	24897.7	12946800	0.9496 84	0.9497 22747	- 3.87475 E-05	1.50137 E-09
40	24896.7	12942900	0.9499 45	0.9499 83157	- 3.81572 E-05	1.45597 E-09
41	24895.9	12911400	0.9501 51	0.9501 8723	- 3.62298 E-05	1.3126E- 09
42	24895.1	12855800	0.9503 07	0.9503 3969	- 3.26895 E-05	1.06861 E-09
43	24894.3	12779800	0.9504 24	0.9504 48217	- 2.42174 E-05	5.86481 E-10
44	24893.6	12686600	0.9505 12	0.9505 29281	- 1.72806 E-05	2.98619 E-10
45	24892.9	12579200	0.9505 85	0.9505 91507	- 6.50693 E-06	4.23401 E-11
46	24892.2	12460400	0.9506 55	0.9506 52481	2.5186 E-06	6.34336 E-12
47	24891.5	12332500	0.9507 31	0.9507 21982	9.01796 E-06	8.13236 E-11
48	24890.6	12197700	0.9508 23	0.9508 05892	1.71075 E-05	2.92668 E-10
49	24889.7	12057600	0.9509 36	0.9509 15105	2.0895 E-05	4.36602 E-10

50	24888.7	11914000	0.9510 76	0.9510 49654	2.6346 E-05	6.9411E- 10
51	24887.5	11768000	0.9512 43	0.9512 16574	2.64264 E-05	6.98353 E-10
52	24886.2	11621100	0.9514 38	0.9514 10057	2.79427 E-05	7.80796 E-10
53	24884.7	11474200	0.9516 59	0.9516 32165	2.68351 E-05	7.20121 E-10
54	24883.1	11328400	0.9519 01	0.9518 78095	2.29052 E-05	5.2465E- 10
55	24881.3	11184600	0.9521 62	0.9521 40047	2.19525 E-05	4.81913 E-10
56	24879.4	11043700	0.9524 36	0.9524 19098	1.69022 E-05	2.85684 E-10
57	24877.4	10906700	0.9527 18	0.9527 05441	1.25595 E-05	1.5774E- 10
58	24875.2	10774200	0.9530 03	0.9529 95121	7.87947 E-06	6.20861 E-11
59	24873	10647200	0.9532 87	0.9532 83098	3.9019 E-06	1.52248 E-11
60	24870.6	10526600	0.9535 65	0.9535 66154	- 1.154E- 06	1.33172 E-12
61	24868.2	10413100	0.9538 34	0.9538 38154	- 4.15442 E-06	1.72592 E-11
62	24865.7	10307600	0.9540 91	0.9540 97733	- 6.73303 E-06	4.53337 E-11
63	24863.2	10210900	0.9543 31	0.9543 41826	- 1.08257 E-05	1.17197 E-10
64	24860.6	10123800	0.9545 54	0.9545 63465	- 9.46547 E-06	8.95952 E-11
65	24857.9	10047200	0.9547 58	0.9547 67698	- 9.69802 E-06	9.40516 E-11
66	24855.3	9981710	0.9549 42	0.9549 50785	- 8.78533 E-06	7.7182E- 11
67	24852.7	9928170	0.9551 05	0.9551 12886	- 7.88552 E-06	6.21814 E-11

68	24850	9887200	0.9552 48	0.9552 53269	- 5.26851 E-06	2.77572 E-11
69	24847.3	9859350	0.9553 7	0.9553 75025	- 5.02454 E-06	2.5246E- 11
70	24844.7	9845080	0.9554 73	0.9554 75291	- 2.29079 E-06	5.24772 E-12
71	24842.1	9844700	0.9555 58	0.9555 59058	- 1.05803 E-06	1.11943 E-12
72	24839.5	9858350	0.9556 26	0.9556 26439	- 4.39286 E-07	1.92972 E-13
73	24836.9	9885970	0.9556 81	0.9556 78448	2.55234 E-06	6.51444 E-12
74	24834.3	9927290	0.9557 23	0.9557 22	1.00021 E-06	1.00042 E-12
75	24831.7	9981790	0.9557 56	0.9557 53206	2.79443 E-06	7.80887 E-12
76	24829.1	10048700	0.9557 81	0.9557 79894	1.10555 E-06	1.22223 E-12
77	24826.6	10127000	0.9558 03	0.9558 0006	2.93967 E-06	8.64166 E-12
78	24824	10215500	0.9558 23	0.9558 22394	6.05828 E-07	3.67028 E-13
79	24821.4	10312500	0.9558 44	0.9558 43837	1.62702 E-07	2.64719 E-14
80	24818.8	10416600	0.9558 67	0.9558 68949	- 1.94912 E-06	3.79906 E-12
81	24816.2	10525800	0.9558 94	0.9558 96518	- 2.51792 E-06	6.3399E- 12
82	24813.6	10638200	0.9559 27	0.9559 29245	- 2.2453 E-06	5.04139 E-12
83	24810.9	10751900	0.9559 63	0.9559 69042	- 6.04151 E-06	3.64998 E-11
84	24808.2	10864700	0.9560 06	0.9560 08174	- 2.17405 E-06	4.72651 E-12

85	24805.5	10974900	0.9560 52	0.9560 57594	- 5.59358 E-06	3.12881 E-11
86	24802.8	11080600	0.9561 01	0.9561 05854	- 4.85385 E-06	2.35598 E-11
87	24800	11180200	0.9561 52	0.9561 57037	- 5.03687 E-06	2.537E- 11
88	24797.2	11272200	0.9562 02	0.9562 09326	- 7.3259 E-06	5.36688 E-11
89	24794.4	11355500	0.9562 49	0.9562 5779	- 8.78969 E-06	7.72586 E-11
90	24791.6	11429100	0.9562 92	0.9563 01417	- 9.41685 E-06	8.86771 E-11
91	24788.8	11492300	0.9563 29	0.9563 40139	- 1.11394 E-05	1.24086 E-10
92	24786	11544700	0.9563 59	0.9563 70956	- 1.19559 E-05	1.42943 E-10
93	24783.2	11586000	0.9563 8	0.9563 93813	- 1.38127 E-05	1.90791 E-10
94	24780.4	11616400	0.9563 93	0.9564 05721	- 1.27208 E-05	1.61819 E-10
95	24777.7	11635900	0.9563 96	0.9564 10596	- 1.45958 E-05	2.13036 E-10
96	24775	11644900	0.9563 92	0.9564 03501	- 1.15005 E-05	1.32262 E-10
97	24772.3	11644100	0.9563 8	0.9563 92328	- 1.23276 E-05	1.5197E- 10
98	24769.6	11633900	0.9563 62	0.9563 72194	- 1.01936 E-05	1.03909 E-10



99	24766.9	11615200	0.9563 39	0.9563 48	- 9.00033 E-06	8.10059 E-11
100	24764.3	11588600	0.9563 14	0.9563 19798	- 5.79839 E-06	3.36213 E-11
101	24761.6	11555000	0.9562 88	0.9562 92505	- 4.50536 E-06	2.02983 E-11
102	24759	11515100	0.9562 63	0.9562 65238	- 2.23757 E-06	5.00671 E-12
103	24756.4	11469900	0.9562 41	0.9562 40905	9.52565 E-08	9.07379 E-15
104	24753.8	11420200	0.9562 23	0.9562 21568	1.43216 E-06	2.05109 E-12
105	24751.1	11366700	0.9562 11	0.9562 07242	3.75833 E-06	1.41251 E-11
106	24748.5	11310200	0.9562 04	0.9562 00918	3.08248 E-06	9.50171 E-12
107	24745.8	11251400	0.9562 06	0.9561 98649	7.35139 E-06	5.4043E- 11
108	24743.1	11191200	0.9562 13	0.9562 09356	3.64356 E-06	1.32755 E-11
109	24740.4	11130200	0.9562 28	0.9562 21237	6.76279 E-06	4.57354 E-11
110	24737.7	11069100	0.9562 49	0.9562 44095	4.90529 E-06	2.40619 E-11
111	24734.9	11008400	0.9562 77	0.9562 7107	5.92992 E-06	3.51639 E-11
112	24732.1	10948900	0.9563 09	0.9563 06076	2.92362 E-06	8.54756 E-12
113	24729.3	10891000	0.9563 47	0.9563 42185	4.815E- 06	2.31842 E-11
114	24726.5	10835300	0.9563 87	0.9563 86231	7.69079 E-07	5.91483 E-13
115	24723.6	10782400	0.9564 3	0.9564 2837	1.6302 E-06	2.65755 E-12
116	24720.8	10732700	0.9564 74	0.9564 74456	- 4.56347 E-07	2.08253 E-13
117	24717.9	10686600	0.9565 2	0.9565 1949	5.09763 E-07	2.59859 E-13

118	24714.9	10644600	0.9565 64	0.9565 67458	- 3.45817 E-06	1.19589 E-11
119	24712	10607000	0.9566 07	0.9566 09472	- 2.47166 E-06	6.10909 E-12
120	24709.1	10574100	0.9566 48	0.9566 51349	- 3.34946 E-06	1.12189 E-11
121	24706.1	10546200	0.9566 87	0.9566 90232	- 3.23243 E-06	1.04486 E-11
122	24703.2	10523600	0.9567 22	0.9567 27119	- 5.11893 E-06	2.62034 E-11
123	24700.2	10506200	0.9567 54	0.9567 58034	- 4.03446 E-06	1.62769 E-11
124	24697.3	10494300	0.9567 82	0.9567 8699	- 4.99037 E-06	2.49038 E-11
125	24694.3	10487900	0.9568 07	0.9568 10999	- 3.99929 E-06	1.59944 E-11
126	24691.4	10487000	0.9568 28	0.9568 33098	- 5.09816 E-06	2.59912 E-11
127	24688.4	10491400	0.9568 45	0.9568 50274	- 5.27394 E-06	2.78144 E-11
128	24685.5	10501000	0.9568 59	0.9568 63582	- 4.58205 E-06	2.09952 E-11
129	24682.5	10515700	0.9568 69	0.9568 74909	- 5.90928 E-06	3.49196 E-11
130	24679.6	10535000	0.9568 76	0.9568 81393	- 5.393E- 06	2.90845 E-11
131	24676.6	10558600	0.9568 81	0.9568 85859	- 4.85924 E-06	2.36123 E-11

132	24673.7	10586100	0.9568 84	0.9568 89378	- 5.37812 E-06	2.89242 E-11
133	24670.8	10617100	0.9568 83	0.9568 90867	- 7.86659 E-06	6.18833 E-11
134	24667.9	10651000	0.9568 82	0.9568 86426	- 4.42638 E-06	1.95928 E-11
135	24664.9	10687300	0.9568 79	0.9568 85827	- 6.82718 E-06	4.66103 E-11
136	24662	10725400	0.9568 74	0.9568 81249	- 7.2485 E-06	5.25408 E-11
137	24659.1	10764700	0.9568 68	0.9568 74552	- 6.55188 E-06	4.29272 E-11
138	24656.2	10804600	0.9568 61	0.9568 67763	- 6.76311 E-06	4.57397 E-11
139	24653.3	10844500	0.9568 53	0.9568 59888	- 6.88801 E-06	4.74447 E-11
140	24650.5	10883900	0.9568 44	0.9568 50932	- 6.9315 E-06	4.80457 E-11
141	24647.6	10922100	0.9568 34	0.9568 40886	- 6.88587 E-06	4.74152 E-11
142	24644.7	10958700	0.9568 24	0.9568 29818	- 5.81824 E-06	3.38519 E-11
143	24641.8	10993200	0.9568 12	0.9568 19661	- 7.66146 E-06	5.8698E- 11
144	24639	11025100	0.9567 99	0.9568 05533	- 6.53313 E-06	4.26817 E-11
145	24636.1	11054200	0.9567 85	0.9567 91339	- 6.33889 E-06	4.01815 E-11

146	24633.3	11080000	0.9567 7	0.9567 76185	- 6.18484 E-06	3.82522 E-11
147	24630.4	11102300	0.9567 54	0.9567 5999	- 5.9899 E-06	3.5879E- 11
148	24627.6	11120900	0.9567 37	0.9567 42846	- 5.84591 E-06	3.41747 E-11
149	24624.8	11135800	0.9567 18	0.9567 24679	- 6.67945 E-06	4.4615E- 11
150	24622	11146900	0.9566 99	0.9567 03584	- 4.58387 E-06	2.10119 E-11
151	24619.2	11154200	0.9566 8	0.9566 84451	- 4.45088 E-06	1.98104 E-11
152	24616.4	11157700	0.9566 59	0.9566 65339	- 6.33891 E-06	4.01818 E-11
153	24613.6	11157700	0.9566 39	0.9566 42306	- 3.30611 E-06	1.09303 E-11
154	24610.9	11154200	0.9566 19	0.9566 23218	- 4.21798 E-06	1.77913 E-11
155	24608.1	11147500	0.9565 99	0.9566 03157	- 4.15715 E-06	1.72819 E-11
156	24605.3	11137800	0.9565 79	0.9565 8316	- 4.16002 E-06	1.73057 E-11
157	24602.6	11125200	0.9565 61	0.9565 63168	- 2.16756 E-06	4.69831 E-12
158	24599.8	11110200	0.9565 43	0.9565 47117	- 4.11721 E-06	1.69515 E-11
159	24597.1	11092900	0.9565 27	0.9565 29187	- 2.18747 E-06	4.78502 E-12

160	24594.3	11073700	0.9565 13	0.9565 15178	- 2.17796 E-06	4.74351 E-12
161	24591.6	11052800	0.9565 01	0.9565 03225	- 2.22471 E-06	4.94935 E-12
162	24588.8	11030700	0.9564 91	0.9564 93243	- 2.24335 E-06	5.03263 E-12
163	24586.1	11007500	0.9564 84	0.9564 85316	- 1.3156 E-06	1.7308E- 12
164	24583.3	10983600	0.9564 79	0.9564 8132	- 2.32035 E-06	5.38401 E-12
165	24580.6	10959300	0.9564 76	0.9564 78396	- 2.39577 E-06	5.73974 E-12
166	24577.8	10935000	0.9564 74	0.9564 7743	- 3.42959 E-06	1.17621 E-11
167	24575	10910700	0.9564 75	0.9564 76528	- 1.52812 E-06	2.33514 E-12
168	24572.3	10887000	0.9564 78	0.9564 80533	- 2.53335 E-06	6.41785 E-12
169	24569.5	10863900	0.9564 82	0.9564 85541	- 3.54096 E-06	1.25384 E-11
170	24566.7	10841700	0.9564 87	0.9564 90594	- 3.59363 E-06	1.29142 E-11
171	24563.9	10820700	0.9564 93	0.9564 96613	- 3.61255 E-06	1.30505 E-11
172	24561.1	10801200	0.9565	0.9565 03618	- 3.61776 E-06	1.30882 E-11
173	24558.3	10783200	0.9565 08	0.9565 11611	- 3.6108 E-06	1.30379 E-11

174	24555.5	10766900	0.9565 15	0.9565 20585	- 5.58511 E-06	3.11934 E-11
175	24552.7	10752500	0.9565 23	0.9565 26607	- 3.6067 E-06	1.30083 E-11
176	24549.9	10740100	0.9565 3	0.9565 3557	- 5.57033 E-06	3.10285 E-11
177	24547.1	10729700	0.9565 37	0.9565 41587	- 4.58707 E-06	2.10412 E-11
178	24544.3	10721500	0.9565 44	0.9565 48577	- 4.57718 E-06	2.09506 E-11
179	24541.5	10715500	0.9565 5	0.9565 55578	- 5.57756 E-06	3.11092 E-11
180	24538.6	10711600	0.9565 55	0.9565 60615	- 5.61479 E-06	3.15258 E-11
181	24535.8	10709900	0.9565 59	0.9565 64683	- 5.68332 E-06	3.23001 E-11
182	24533	10710300	0.9565 63	0.9565 67728	- 4.72846 E-06	2.23583 E-11
183	24530.2	10712600	0.9565 66	0.9565 7178	- 5.78043 E-06	3.34134 E-11
184	24527.4	10716900	0.9565 67	0.9565 7387	- 6.86971 E-06	4.71929 E-11
185	24524.6	10722900	0.9565 69	0.9565 73007	- 4.00679 E-06	1.60543 E-11
186	24521.8	10730600	0.9565 68	0.9565 76067	- 8.06749 E-06	6.50844 E-11
187	24519	10739700	0.9565 68	0.9565 7225	- 4.25028 E-06	1.80649 E-11

188	24516.2	10750200	0.9565 65	0.9565 73326	- 8.32583 E-06	6.93194 E-11
189	24513.4	10761700	0.9565 63	0.9565 67518	- 4.51802 E-06	2.04125 E-11
190	24510.6	10774100	0.9565 6	0.9565 66595	- 6.59451 E-06	4.34876 E-11
191	24507.8	10787200	0.9565 55	0.9565 62722	- 7.72215 E-06	5.96316 E-11
192	24505	10800800	0.9565 5	0.9565 55872	- 5.87154 E-06	3.44749 E-11
193	24502.2	10814600	0.9565 44	0.9565 50958	- 6.9583 E-06	4.8418E- 11
194	24499.5	10828500	0.9565 37	0.9565 44058	- 7.05821 E-06	4.98183 E-11
195	24496.7	10842200	0.9565 3	0.9565 36129	- 6.12906 E-06	3.75654 E-11
196	24493.9	10855600	0.9565 21	0.9565 29199	- 8.19909 E-06	6.7225E- 11
197	24491.2	10868500	0.9565 12	0.9565 18294	- 6.29384 E-06	3.96124 E-11
198	24488.4	10880700	0.9565 02	0.9565 09303	- 7.30312 E-06	5.33355 E-11
Jumlah						1.82927 E-07

Penghitungan nilai MSE

$$MSE = \frac{\sum_{i=1}^n (y - y_i)^2}{N}$$

$$MSE = \frac{1.82927 \times 10^{-7}}{198}$$

$$MSE = 9.23872 \times 10^{-10}$$

**Tabel C.2** Tabel perhitungan *error* pengujian model MISO2

No	L	Qr	Xb	Xb Pred	Error	Error <sup>2</sup>
1	24899.7	10068000	0.0101 338	0.0096 12083	0.00052 1717	2.72188 E-07
2	24897.1	9791540	0.0091 8082	0.0091 84407	- 3.587E- 06	1.28666 E-11
3	24894.5	9544180	0.0085 5096	0.0086 7523	- 0.00012 427	1.54431 E-08
4	24892	9316560	0.0081 3798	0.0083 02563	- 0.00016 4583	2.70874 E-08
5	24889.7	9104790	0.0078 8506	0.0080 67152	- 0.00018 2092	3.31575 E-08
6	24887.6	8906520	0.0077 5352	0.0079 48092	- 0.00019 4572	3.78583 E-08
7	24885.6	8719380	0.0077 1022	0.0079 16328	- 0.00020 6108	4.24804 E-08
8	24883.8	8542970	0.0077 3965	0.0079 38821	- 0.00019 9171	3.96689 E-08
9	24882.3	8382870	0.0078 6537	0.0080 10489	- 0.00014 5119	2.10595 E-08
10	24881	8244120	0.0081 0339	0.0081 84353	- 8.09633 E-05	6.55506 E-09
11	24880	8129510	0.0084 5345	0.0084 75536	- 2.20856 E-05	4.87775 E-10
12	24879.3	8039900	0.0089 0382	0.0088 76536	2.72843 E-05	7.44435 E-10
13	24878.9	7977630	0.0094 5368	0.0093 71547	8.21334 E-05	6.7459E- 09
14	24878.9	7945270	0.0101 036	0.0099 71594	0.00013 2006	1.74255 E-08
15	24879.2	7945150	0.0108 525	0.0106 81522	0.00017 0978	2.92334 E-08



16	24879.8	7979290	0.0116 979	0.0115 01987	0.00019 5913	3.83818 E-08
17	24880.8	8048980	0.0126 328	0.0124 3059	0.00020 221	4.08888 E-08
18	24882.1	8154400	0.0136 444	0.0134 56142	0.00018 8258	3.54412 E-08
19	24883.7	8294520	0.0147 148	0.0145 58786	0.00015 6014	2.43402 E-08
20	24885.5	8467420	0.0158 231	0.0157 10717	0.00011 2383	1.26299 E-08
21	24887.5	8670340	0.0169 465	0.0168 80164	6.63361 E-05	4.40048 E-09
22	24889.7	8900130	0.0180 632	0.0180 31796	3.14036 E-05	9.86187 E-10
23	24891.8	9155840	0.0191 688	0.0191 33557	3.52429 E-05	1.24206 E-09
24	24894	9432640	0.0202 348	0.0201 87893	4.69065 E-05	2.20022 E-09
25	24896	9726650	0.0212 437	0.0211 54435	8.92652 E-05	7.96827 E-09
26	24897.9	10040100	0.0222 185	0.0220 46629	0.00017 1871	2.95397 E-08
27	24899.5	10374600	0.0231 74	0.0229 39797	0.00023 4203	5.48512 E-08
28	24900.9	10719500	0.0240 455	0.0238 50516	0.00019 4984	3.8019E- 08
29	24901.9	11061600	0.0247 67	0.0246 47519	0.00011 9481	1.42757 E-08
30	24902.6	11391400	0.0253 016	0.0252 41532	6.00675 E-05	3.60811 E-09
31	24902.9	11700900	0.0256 292	0.0256 01909	2.72911 E-05	7.44807 E-10
32	24903	11983400	0.0257 405	0.0257 21843	1.8657 E-05	3.48085 E-10
33	24902.7	12233500	0.0256 357	0.0256 09281	2.64194 E-05	6.97986 E-10
34	24902.1	12447600	0.0253 25	0.0252 81611	4.33885 E-05	1.88256 E-09
35	24901.4	12623300	0.0248 262	0.0247 64573	6.16272 E-05	3.79791 E-09
36	24900.5	12760000	0.0241 635	0.0240 86729	7.67713 E-05	5.89384 E-09
37	24899.6	12858200	0.0233 657	0.0232 78933	8.67667 E-05	7.52846 E-09

38	24898.6	12919600	0.0224 638	0.0223 73197	9.06033 E-05	8.20896 E-09
39	24897.7	12946800	0.0214 894	0.0214 00005	8.93946 E-05	7.99139 E-09
40	24896.7	12942900	0.0204 729	0.0203 88553	8.43468 E-05	7.11438 E-09
41	24895.9	12911400	0.0194 423	0.0193 65005	7.72946 E-05	5.97446 E-09
42	24895.1	12855800	0.0184 216	0.0183 5275	6.88499 E-05	4.74031 E-09
43	24894.3	12779800	0.0174 311	0.0173 70218	6.08818 E-05	3.7066E- 09
44	24893.6	12686600	0.0164 863	0.0164 33137	5.31633 E-05	2.82634 E-09
45	24892.9	12579200	0.0155 99	0.0155 52351	4.66486 E-05	2.17609 E-09
46	24892.2	12460400	0.0147 77	0.0147 36212	4.07884 E-05	1.66369 E-09
47	24891.5	12332500	0.0140 248	0.0139 89328	3.54723 E-05	1.25829 E-09
48	24890.6	12197700	0.0133 446	0.0133 1384	3.07604 E-05	9.46202 E-10
49	24889.7	12057600	0.0127 365	0.0127 10421	2.60794 E-05	6.80136 E-10
50	24888.7	11914000	0.0121 99	0.0121 77964	2.10355 E-05	4.42493 E-10
51	24887.5	11768000	0.0117 297	0.0117 14048	1.56517 E-05	2.44974 E-10
52	24886.2	11621100	0.0113 258	0.0113 1593	9.86961 E-06	9.74093 E-11
53	24884.7	11474200	0.0109 841	0.0109 80651	3.44942 E-06	1.18985 E-11
54	24883.1	11328400	0.0107 012	0.0107 04881	- 3.68087 E-06	1.35488 E-11
55	24881.3	11184600	0.0104 739	0.0104 85041	- 1.11413 E-05	1.24129 E-10
56	24879.4	11043700	0.0102 992	0.0103 17997	- 1.87969 E-05	3.53324 E-10
57	24877.4	10906700	0.0101 746	0.0102 00652	- 2.6052 E-05	6.78709 E-10

58	24875.2	10774200	0.0100 975	0.0101 30543	- 3.30434 E-05	1.09187 E-09
59	24873	10647200	0.0100 659	0.0101 04695	- 3.87949 E-05	1.50505 E-09
60	24870.6	10526600	0.0100 781	0.0101 21154	- 4.30542 E-05	1.85367 E-09
61	24868.2	10413100	0.0101 323	0.0101 78137	- 4.58374 E-05	2.10107 E-09
62	24865.7	10307600	0.0102 274	0.0102 73754	- 4.63542 E-05	2.14871 E-09
63	24863.2	10210900	0.0103 622	0.0104 07354	- 4.51544 E-05	2.03892 E-09
64	24860.6	10123800	0.0105 357	0.0105 77906	- 4.22063 E-05	1.78138 E-09
65	24857.9	10047200	0.0107 468	0.0107 84756	- 3.79557 E-05	1.44064 E-09
66	24855.3	9981710	0.0109 945	0.0110 26943	- 3.24432 E-05	1.05256 E-09
67	24852.7	9928170	0.0112 776	0.0113 03956	- 2.63565 E-05	6.94664 E-10
68	24850	9887200	0.0115 949	0.0116 1431	- 1.94104 E-05	3.76765 E-10
69	24847.3	9859350	0.0119 444	0.0119 56895	- 1.24946 E-05	1.56115 E-10
70	24844.7	9845080	0.0123 24	0.0123 29077	- 5.07673 E-06	2.57731 E-11
71	24842.1	9844700	0.0127 311	0.0127 28572	2.52751 E-06	6.38828 E-12
72	24839.5	9858350	0.0131 622	0.0131 52247	9.95335 E-06	9.90693 E-11

73	24836.9	9885970	0.0136 134	0.0135 95891	1.75087 E-05	3.06556 E-10
74	24834.3	9927290	0.0140 799	0.0140 55363	2.45369 E-05	6.0206E- 10
75	24831.7	9981790	0.0145 561	0.0145 2534	3.07602 E-05	9.4619E- 10
76	24829.1	10048700	0.0150 358	0.0149 99918	3.58817 E-05	1.28749 E-09
77	24826.6	10127000	0.0155 123	0.0154 72848	3.94522 E-05	1.55648 E-09
78	24824	10215500	0.0159 783	0.0159 37541	4.07592 E-05	1.66131 E-09
79	24821.4	10312500	0.0164 262	0.0163 86437	3.97629 E-05	1.58109 E-09
80	24818.8	10416600	0.0168 484	0.0168 12233	3.61665 E-05	1.30802 E-09
81	24816.2	10525800	0.0172 376	0.0172 0701	3.05901 E-05	9.35754 E-10
82	24813.6	10638200	0.0175 871	0.0175 63701	2.33992 E-05	5.47524 E-10
83	24810.9	10751900	0.0178 905	0.0178 75554	1.49463 E-05	2.23392 E-10
84	24808.2	10864700	0.0181 427	0.0181 35888	6.81176 E-06	4.64E-11
85	24805.5	10974900	0.0183 397	0.0183 40465	- 7.65075 E-07	5.85339 E-13
86	24802.8	11080600	0.0184 792	0.0184 85778	- 6.57793 E-06	4.32692 E-11
87	24800	11180200	0.0185 595	0.0185 71035	- 1.15354 E-05	1.33066 E-10
88	24797.2	11272200	0.0185 811	0.0185 95239	- 1.41392 E-05	1.99916 E-10
89	24794.4	11355500	0.0185 457	0.0185 61086	- 1.53865 E-05	2.36744 E-10
90	24791.6	11429100	0.0184 561	0.0184 7164	- 1.55395 E-05	2.41476 E-10

91	24788.8	11492300	0.0183 164	0.0183 31057	- 1.46572 E-05	2.14833 E-10
92	24786	11544700	0.0181 314	0.0181 44833	- 1.34334 E-05	1.80457 E-10
93	24783.2	11586000	0.0179 066	0.0179 18597	- 1.1997 E-05	1.43928 E-10
94	24780.4	11616400	0.0176 485	0.0176 58593	- 1.00934 E-05	1.01877 E-10
95	24777.7	11635900	0.0173 634	0.0173 72095	- 8.69485 E-06	7.56005 E-11
96	24775	11644900	0.0170 578	0.0170 65293	- 7.49335 E-06	5.61503 E-11
97	24772.3	11644100	0.0167 378	0.0167 44717	- 6.91682 E-06	4.78424 E-11
98	24769.6	11633900	0.0164 096	0.0164 15976	- 6.37579 E-06	4.06507 E-11
99	24766.9	11615200	0.0160 786	0.0160 85213	- 6.61283 E-06	4.37295 E-11
100	24764.3	11588600	0.0157 501	0.0157 56985	- 6.88467 E-06	4.73987 E-11
101	24761.6	11555000	0.0154 286	0.0154 36356	- 7.75642 E-06	6.0162E- 11
102	24759	11515100	0.0151 181	0.0151 27023	- 8.92286 E-06	7.96174 E-11
103	24756.4	11469900	0.0148 22	0.0148 32447	- 1.04474 E-05	1.09148 E-10
104	24753.8	11420200	0.0145 432	0.0145 55392	- 1.21921 E-05	1.48647 E-10

105	24751.1	11366700	0.0142 838	0.0142 98237	- 1.44372 E-05	2.08432 E-10
106	24748.5	11310200	0.0140 458	0.0140 62368	- 1.65678 E-05	2.74492 E-10
107	24745.8	11251400	0.0138 305	0.0138 49556	- 1.90561 E-05	3.63135 E-10
108	24743.1	11191200	0.0136 389	0.0136 60472	- 2.15721 E-05	4.65355 E-10
109	24740.4	11130200	0.0134 716	0.0134 95704	- 2.41044 E-05	5.8102E- 10
110	24737.7	11069100	0.0133 291	0.0133 55469	- 2.63691 E-05	6.9533E- 10
111	24734.9	11008400	0.0132 116	0.0132 40047	- 2.84469 E-05	8.09227 E-10
112	24732.1	10948900	0.0131 187	0.0131 4933	- 3.06298 E-05	9.38183 E-10
113	24729.3	10891000	0.0130 504	0.0130 8229	- 3.18904 E-05	1.017E- 09
114	24726.5	10835300	0.0130 062	0.0130 39223	- 3.30231 E-05	1.09052 E-09
115	24723.6	10782400	0.0129 855	0.0130 19128	- 3.36281 E-05	1.13085 E-09
116	24720.8	10732700	0.0129 877	0.0130 21237	- 3.35373 E-05	1.12475 E-09
117	24717.9	10686600	0.0130 119	0.0130 45033	- 3.31335 E-05	1.09783 E-09
118	24714.9	10644600	0.0130 573	0.0130 8931	- 3.20102 E-05	1.02465 E-09

119	24712	10607000	0.0131 23	0.0131 5334	- 3.03399 E-05	9.20508 E-10
120	24709.1	10574100	0.0132 077	0.0132 363	-2.86E- 05	8.1796E- 10
121	24706.1	10546200	0.0133 103	0.0133 36551	- 2.62507 E-05	6.89102 E-10
122	24703.2	10523600	0.0134 293	0.0134 53167	- 2.38667 E-05	5.69621 E-10
123	24700.2	10506200	0.0135 629	0.0135 84463	- 2.15627 E-05	4.6495E- 10
124	24697.3	10494300	0.0137 095	0.0137 28505	- 1.9005 E-05	3.61191 E-10
125	24694.3	10487900	0.0138 675	0.0138 8382	- 1.63199 E-05	2.66338 E-10
126	24691.4	10487000	0.0140 349	0.0140 4883	- 1.39302 E-05	1.9405E- 10
127	24688.4	10491400	0.0142 098	0.0142 21379	- 1.15792 E-05	1.34077 E-10
128	24685.5	10501000	0.0143 9	0.0143 99619	- 9.6195 E-06	9.25348 E-11
129	24682.5	10515700	0.0145 732	0.0145 81222	- 8.02159 E-06	6.4346E- 11
130	24679.6	10535000	0.0147 573	0.0147 63671	- 6.37132 E-06	4.05938 E-11
131	24676.6	10558600	0.0149 399	0.0149 45364	- 5.46392 E-06	2.98544 E-11
132	24673.7	10586100	0.0151 185	0.0151 23444	- 4.94402 E-06	2.44433 E-11
133	24670.8	10617100	0.0152 91	0.0152 95525	- 4.5253 E-06	2.04783 E-11

134	24667.9	10651000	0.0154 551	0.0154 59717	- 4.61729 E-06	2.13193 E-11
135	24664.9	10687300	0.0156 088	0.0156 13696	- 4.89578 E-06	2.39686 E-11
136	24662	10725400	0.0157 5	0.0157 55614	- 5.61431 E-06	3.15205 E-11
137	24659.1	10764700	0.0158 771	0.0158 83453	- 6.35303 E-06	4.0361E- 11
138	24656.2	10804600	0.0159 884	0.0159 95917	- 7.51652 E-06	5.6498E- 11
139	24653.3	10844500	0.0160 828	0.0160 91279	- 8.47867 E-06	7.18878 E-11
140	24650.5	10883900	0.0161 592	0.0161 68928	- 9.72821 E-06	9.4638E- 11
141	24647.6	10922100	0.0162 171	0.0162 27796	- 1.06961 E-05	1.14407 E-10
142	24644.7	10958700	0.0162 561	0.0162 67887	- 1.17868 E-05	1.38929 E-10
143	24641.8	10993200	0.0162 763	0.0162 889	- 1.26002 E-05	1.58766 E-10
144	24639	11025100	0.0162 776	0.0162 91396	- 1.37963 E-05	1.90339 E-10
145	24636.1	11054200	0.0162 607	0.0162 75226	- 1.45263 E-05	2.11013 E-10
146	24633.3	11080000	0.0162 265	0.0162 41603	- 1.51025 E-05	2.28086 E-10
147	24630.4	11102300	0.0161 762	0.0161 9182	- 1.56202 E-05	2.43989 E-10



148	24627.6	11120900	0.0161 111	0.0161 27215	- 1.61153 E-05	2.59703 E-10
149	24624.8	11135800	0.0160 328	0.0160 49284	- 1.64839 E-05	2.7172E- 10
150	24622	11146900	0.0159 43	0.0159 59792	- 1.67916 E-05	2.81958 E-10
151	24619.2	11154200	0.0158 434	0.0158 60582	- 1.71817 E-05	2.95212 E-10
152	24616.4	11157700	0.0157 362	0.0157 53349	- 1.71493 E-05	2.94099 E-10
153	24613.6	11157700	0.0156 235	0.0156 4068	- 1.71796 E-05	2.9514E- 10
154	24610.9	11154200	0.0155 069	0.0155 24503	- 1.76028 E-05	3.09858 E-10
155	24608.1	11147500	0.0153 881	0.0154 06121	- 1.80205 E-05	3.2474E- 10
156	24605.3	11137800	0.0152 688	0.0152 87168	- 1.83685 E-05	3.37402 E-10
157	24602.6	11125200	0.0151 505	0.0151 69363	- 1.88629 E-05	3.5581E- 10
158	24599.8	11110200	0.0150 348	0.0150 54061	- 1.92606 E-05	3.70971 E-10
159	24597.1	11092900	0.0149 231	0.0149 42739	- 1.96387 E-05	3.85679 E-10
160	24594.3	11073700	0.0148 166	0.0148 36752	- 2.01516 E-05	4.06089 E-10
161	24591.6	11052800	0.0147 165	0.0147 36972	- 2.04719 E-05	4.19099 E-10

162	24588.8	11030700	0.0146 235	0.0146 44655	- 2.11549 E-05	4.47531 E-10
163	24586.1	11007500	0.0145 385	0.0145 59925	- 2.14254 E-05	4.59049 E-10
164	24583.3	10983600	0.0144 622	0.0144 8396	- 2.176E- 05	4.73496 E-10
165	24580.6	10959300	0.0143 951	0.0144 17115	- 2.20146 E-05	4.84641 E-10
166	24577.8	10935000	0.0143 376	0.0143 59782	- 2.21816 E-05	4.92024 E-10
167	24575	10910700	0.0142 898	0.0143 12134	- 2.23343 E-05	4.98819 E-10
168	24572.3	10887000	0.0142 521	0.0142 74205	- 2.2105 E-05	4.8863E- 10
169	24569.5	10863900	0.0142 244	0.0142 46385	- 2.19853 E-05	4.83353 E-10
170	24566.7	10841700	0.0142 068	0.0142 28312	- 2.15123 E-05	4.62777 E-10
171	24563.9	10820700	0.0141 99	0.0142 20175	- 2.1175 E-05	4.48379 E-10
172	24561.1	10801200	0.0142 012	0.0142 21326	- 2.01262 E-05	4.05065 E-10
173	24558.3	10783200	0.0142 126	0.0142 32318	- 1.97178 E-05	3.88793 E-10
174	24555.5	10766900	0.0142 329	0.0142 51708	- 1.88081 E-05	3.53745 E-10
175	24552.7	10752500	0.0142 616	0.0142 79495	- 1.78954 E-05	3.20246 E-10

176	24549.9	10740100	0.0142 982	0.0143 15018	- 1.68178 E-05	2.82839 E-10
177	24547.1	10729700	0.0143 419	0.0143 57812	- 1.59119 E-05	2.53188 E-10
178	24544.3	10721500	0.0143 921	0.0144 06898	- 1.47977 E-05	2.18972 E-10
179	24541.5	10715500	0.0144 479	0.0144 61739	- 1.38388 E-05	1.91512 E-10
180	24538.6	10711600	0.0145 086	0.0145 21291	- 1.2691 E-05	1.61062 E-10
181	24535.8	10709900	0.0145 73	0.0145 85026	- 1.20261 E-05	1.44628 E-10
182	24533	10710300	0.0146 406	0.0146 51372	- 1.07715 E-05	1.16025 E-10
183	24530.2	10712600	0.0147 101	0.0147 20365	- 1.0265 E-05	1.05369 E-10
184	24527.4	10716900	0.0147 806	0.0147 90183	- 9.58321 E-06	9.18379 E-11
185	24524.6	10722900	0.0148 513	0.0148 60098	- 8.79847 E-06	7.74131 E-11
186	24521.8	10730600	0.0149 212	0.0149 29573	- 8.37279 E-06	7.01036 E-11
187	24519	10739700	0.0149 896	0.0149 97331	- 7.7309 E-06	5.97668 E-11
188	24516.2	10750200	0.0150 553	0.0150 63045	- 7.74476 E-06	5.99812 E-11
189	24513.4	10761700	0.0151 177	0.0151 25012	- 7.31166 E-06	5.34604 E-11

190	24510.6	10774100	0.0151 761	0.0151 83279	- 7.17862 E-06	5.15326 E-11
191	24507.8	10787200	0.0152 298	0.0152 36956	- 7.15628 E-06	5.12124 E-11
192	24505	10800800	0.0152 781	0.0152 854	- 7.29995 E-06	5.32893 E-11
193	24502.2	10814600	0.0153 207	0.0153 27926	- 7.22578 E-06	5.22119 E-11
194	24499.5	10828500	0.0153 571	0.0153 64601	- 7.50091 E-06	5.62637 E-11
195	24496.7	10842200	0.0153 87	0.0153 94739	- 7.73851 E-06	5.98846 E-11
196	24493.9	10855600	0.0154 102	0.0154 18205	- 8.00545 E-06	6.40872 E-11
197	24491.2	10868500	0.0154 266	0.0154 34892	- 8.29192 E-06	6.8756E- 11
198	24488.4	10880700	0.0154 363	0.0154 44839	- 8.53938 E-06	7.2921E- 11
Jumlah						9.89015 E-07

Penghitungan nilai MSE

$$MSE = \frac{\sum_{i=1}^n (y - y_i)^2}{N}$$

$$MSE = \frac{9.89015 \times 10^{-7}}{198}$$

$$MSE = 4.99503 \times 10^{-9}$$

## LAMPIRAN D. Source Code Program Matlab 2013b

### D.1 Pembangkitan Sinyal APRBS

```
function [time,P1] =  
a_p_r_b_s(sampling,length,xmin,xmax,mininterval,  
maxinterval)  
clear all  
close all  
% Fungsi ini berguna utk membangkitkan sinyal  
Amplitude modulated Pseudo  
% Random Binary Signal (APRBS) utk identifikasi  
dari suatu sistem dinamik.  
  
sampling=1; % sampling: waktu sampling  
length=4000; % length: panjang sinyal yang akan  
dibangkitkan  
xmin=25839; % xmin: amplitudo minimal dari  
sinyal  
xmax=27992; % xmax: amplitudo maksimal dari  
sinyal  
mininterval=400; % mininterval: minimal interval  
yg mungkin terjadi dari perubahan nilai sinyal  
maxinterval=800; % maxinterval: maksimal interval  
yg mungkin terjadi dari perubahan nilai sinyal  
  
% Program ini diadopsi di Kai Dadhe et.al  
  
if length/sampling<1  
    error('Variable length lebih kecil dari  
sampling intervall!');  
end  
  
% Generating and plotting APRBS  
P1=aprbbs(floor(length/sampling),mininterval,maxi  
nterval,xmin,xmax);  
time=zeros(size(P1));  
  
for i=1:max(size(time))  
    time(i)=(i-1)*sampling;
```

```

end
stairs(time,P1);

% Local function 1
function P1 = aprbs(n, mist, mast, miny, maxy,
F)
if nargin<5,
    error('Input fungsi ini terdiri dari 5
elemen')
end
if (mist<1),
    mist = 1;
end
if (mast<mist),
    mast = mist;
end
if (n<1),
    n = 1;
end
if (maxy<miny),
    temp = maxy;
    maxy = miny;
    miny = temp;
end
if (nargin<6),
    F = 0.8;
end
if (F<=0),
    F = 0.001;
elseif (F>=1),
    F = 0.999;
end

P10 = prbs(n, mist, mast, F);
P1 = 0;
P10old =P10(1);
value = rand(1)*(maxy-miny)+miny;
P1(1) = value;
for i=2:n
    P10new = P10(i);

```

```

    if (P10new ~= P10old), % State has changed
        value = rand(1)*(maxy-miny)+miny;
    end
    P1(i) = value;
    P10old = P10new;
end
% P2 = P1';
save data.mat P1 %Menyimpan hasil sinyal APRBS

% Local function 2
function P1 = prbs(n, mist, mast, F )
    if (nargin<3),
        error('Input fungsi ini terdiri dari 3
elemen')
    end
    if (mist<1),
        mist = 1;
    end
    if (mast<mist),
        mast = mist;
    end
    if (n<1),
        n = 1;
    end
    if (nargin<4),
        F = 0.8;
    end
    if (F<=0),
        F = 0.001;
    elseif (F>1),
        F = 0.999;
    end
    mini = mist - 0.4999;
    maxi = mast + 0.4999;
    maxu = 1;
    minu = (1 - F) * maxu;
    deltu = maxu - minu;
    delta = (maxi - mini) / log(minu);
    state = sign(rand(1) - 0.5);
    if (state==0),
        state = 1;

```

```

end
j = 1;
P1 = zeros(n,1);
while j <= n
    t = round( mini + log(minu + rand(1) *
deltu) * delta);
    state = -state;
    for k = 1:t,
        P1(j,1) = state;
        j = j + 1;
        if j>n, break, end
    end
end
end

```

## D.2 Pelatihan dan Validasi MISO1

```

clear all
clc
%Pembacaan data
A = xlsread('data5_perlmin.xlsx','IO');% membaca
data dari excel
u = A(1:4000,3:4); % data input
y = A(1:4000,1); % data output / target
X = tonndata(u,false,false);
T = tonndata(y,false,false);

% Pengaturan struktur neural network NARX
inputDelays = 1:2; % delay input (sec)
feedbackDelays = 1:2; % delay feedback/output
(sec)
hiddenLayerSize = 15; % jumlah hidden neurons
net =
narnet(inputDelays,feedbackDelays,hiddenLayerSi
ze);

% Memilih fungsi Pre/Post-Processing input dan
feedback

```



```

net.inputs{1}.processFcns =
{'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns =
{'removeconstantrows','mapminmax'};

% Menyiapkan data untuk pelatihan dan validasi
[x,xi,ai,t] = preparets(net,X,{},T);

% Pembagian data untuk tahap pelatihan dan
validasi
net.divideFcn = 'dividerand'; % membagi data
secara random
net.divideMode = 'value';
net.divideParam.trainRatio = 75/100; % 75% data
pelatihan
net.divideParam.valRatio = 25/100; % 25% data
validasi
net.divideParam.testRatio = 0/100;

% Pemilihan algoritma fungsi pelatihan
net.trainFcn = 'trainlm'; % menggunakan
algoritma Levenberg-Marquardt

% Pemilihan fungsi performa
net.performFcn = 'mse'; % menggunakan kriteria
MSE (Mean squared error)

% Pelatihan neural network
[net,tr] = train(net,x,t,xi,ai);

```

### D.3 Tahap pengujian/testing MISO1

```

% Pembacaan data
B = xlsread('datatesting.xlsx','IO'); % membaca
data excel
ub = B(1:200,3:4); % data input uji
yb = B(1:200,1); % datat output/target uji

```

```

Xb = tonndata(ub,false,false);
Tb = tonndata(yb,false,false);
[xb,xib,aib,tb] = preparets(net,Xb,{},Tb);

% Proses pengujian
ypred = net(xb,xib,aib);
e = gsubtract(tb,ypred); % menghitung error
performance = perform(net,tb,ypred); %
menghitung nilai performa

% Menampilkan grafik hasil pengujian
figure, plotresponse(tb,ypred)

```

#### D.4 Pelatihan dan Validasi MISO2

```

clear all
clc
%Pembacaan data
A = xlsread('data5_perlmin.xlsx','IO');% membaca
data dari excel
u = A(1:4000,3:4); % data input
y = A(1:4000,2); % data output / target
X = tonndata(u,false,false);
T = tonndata(y,false,false);

% Pengaturan struktur neural network NARX
inputDelays = 1:2; % delay input (sec)
feedbackDelays = 1:2; % delay feedback/output
(sec)
hiddenLayerSize = 19; % jumlah hidden neurons
net =
narxnet(inputDelays,feedbackDelays,hiddenLayerSi
ze);

% Memilih fungsi Pre/Post-Processing input dan
feedback
net.inputs{1}.processFcns =
{'removeconstantrows','mapminmax'};

```

```

net.inputs{2}.processFcns =
{'removeconstantrows','mapminmax'};

% Menyiapkan data untuk pelatihan dan validasi
[x,xi,ai,t] = preparets(net,X,{},T);

% Pembagian data untuk tahap pelatihan dan
validasi
net.divideFcn = 'dividerand'; % membagi data
secara random
net.divideMode = 'value';
net.divideParam.trainRatio = 75/100; % 75% data
pelatihan
net.divideParam.valRatio = 25/100; % 25% data
validasi
net.divideParam.testRatio = 0/100;

% Pemilihan algoritma fungsi pelatihan
net.trainFcn = 'trainlm'; % menggunakan
algoritma Levenberg-Marquardt

% Pemilihan fungsi performa
net.performFcn = 'mse'; % menggunakan kriteria
MSE (Mean squared error)

% Pelatihan neural network
[net,tr] = train(net,x,t,xi,ai);

```

## D.5 Tahap pengujian/testing MISO2

```

% Pembacaan data
B = xlsread('datatesting.xlsx','IO'); % membaca
data excel
ub = B(1:200,3:4); % data input uji
yb = B(1:200,2); % data output/target uji
Xb = tonndata(ub,false,false);
Tb = tonndata(yb,false,false);


```

```
[xb,xib,aib,tb] = preparets(net,Xb,{},Tb);


% Proses pengujian
ypred = net(xb,xib,aib);
e = gsubtract(tb,ypred); % menghitung error
performance = perform(net,tb,ypred); %
menghitung nilai performa

% Menampilkan grafik hasil pengujian
figure, plotresponse(tb,ypred)
```


## Lampiran E. Tampilan Skema Rancangan Model dan Pengendali pada MATLAB-Simulink



**Gambar E.1** Model *neural network* kolom *depropanizer* pada MATLAB-Simulink



**Gambar E.2** Rancangan pengendali PI pada MATLAB-Simulink



**Gambar E.3** Rancangan pengendali NN MPC pada MATLAB-Simulink

## BIODATA PENULIS



Febrianto Putro Wicaksono merupakan nama lengkap penulis dengan nama panggilannya, Febri. Penulis dilahirkan di Kediri, pada tanggal 30 Januari 1995 sebagai anak dari pasangan Bapak Sukamto dan Ibu Nanik Siami Arufatin. Penulis merupakan anak kedua dari tiga bersaudara. Riwayat pendidikan penulis adalah: SDN 1 Sumbercangkring (tahun 2001-2003), SDN 1 Tambakrejo (tahun 2003-2007), SMPN 1 Gurah (tahun 2007-2010), SMAN 2 Kediri (tahun 2010-2013) dan mengawali perkuliahan di Departemen Teknik Fisika ITS pada tahun 2013. Selama perkuliahan, penulis aktif sebagai asisten Laboratorium Rekayasa Instrumentasi dan Kontrol (Larins), Departemen Teknik Fisika, ITS. Dalam tugas akhirnya, penulis juga mengambil bidang minat Rekayasa Instrumentasi. Penulis memiliki beberapa hobi yaitu membaca, menonton film, dan bermain game. Penulis dapat dihubungi melalui email: [febriantoputro@gmail.com](mailto:febriantoputro@gmail.com).

